

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY
CAMPUS MONTERREY
PROGRAMA DE GRADUADOS EN MECATRONICA Y
TECNOLOGIAS DE INFORMACION



TECNOLÓGICO
DE MONTERREY

Optimización de Parámetros de Corte y Detección de Desgaste en
Herramienta de Corte para un Proceso de Mecanizado a Alta Velocidad
utilizando Redes Neuronales y Algoritmos Genéticos.

TESIS

PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO ACADÉMICO DE:
MAESTRO EN CIENCIAS CON ESPECIALIDAD
EN AUTOMATIZACIÓN

POR:

RICARDO SANCHEZ RUBIO HERNANDEZ

MONTERREY, N. L.

MAYO DE 2011

**INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY**

CAMPUS MONTERREY

**PROGRAMA DE GRADUADOS EN MECATRÓNICA Y
TECNOLOGÍAS DE INFORMACIÓN**



**TECNOLÓGICO
DE MONTERREY**

**Optimización de Parámetros de Corte y Detección de Desgaste en
Herramienta de Corte para un Proceso de Mecanizado a Alta Velocidad
utilizando Redes Neuronales y Algoritmos Genéticos.**

T E S I S

**PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO ACADÉMICO DE:**

**MAESTRO EN CIENCIAS CON ESPECIALIDAD
EN AUTOMATIZACIÓN**

POR:

RICARDO SANCHEZ RUBIO HERNANDEZ


MONTERREY, N. L.

MAYO DE 2011

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY

CAMPUS MONTERREY

PROGRAMA DE GRADUADOS EN MECATRÓNICA Y
TECNOLOGÍAS DE INFORMACIÓN



**TECNOLÓGICO
DE MONTERREY®**

**Optimización de Parámetros de Corte y Detección de Desgaste en
Herramienta de Corte para un Proceso de Mecanizado a Alta Velocidad
utilizando Redes Neuronales y Algoritmos Genéticos.**

TESIS

PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER EL GRADO
ACADEMICO DE:

MAESTRO EN CIENCIAS CON ESPECIALIDAD EN AUTOMATIZACIÓN

POR:

Ricardo Sánchez Rubio Hernández

MONTERREY, N.L.

Mayo de 2011

INSTITUTO TECNOLÓGICO DE ESTUDIOS SUPERIORES DE MONTERREY

DIVISIÓN DE MECATRÓNICA Y TECNOLOGÍAS DE INFORMACIÓN

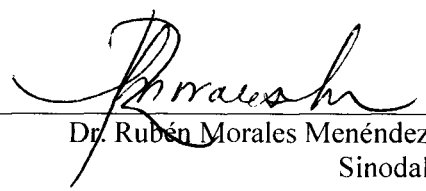
**PROGRAMA DE GRADUADOS EN MECATRÓNICA Y
TECNOLOGÍAS DE INFORMACIÓN**

Los miembros del comité de tesis recomendamos que la presente tesis del Ingeniero en Mecatrónica Ricardo Sánchez Rubio Hernández sea aceptada como requisito parcial para obtener el grado académico de Maestro en Ciencias con Especialidad en Automatización.

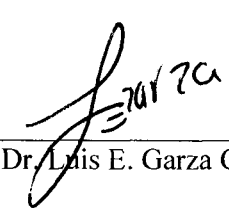
Comité de tesis:



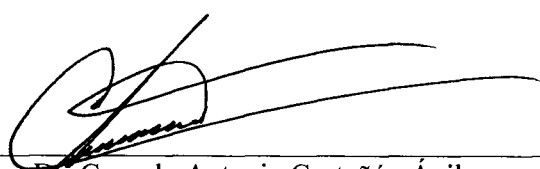
Dr. Antonio Jr. Vallejo Guevara
Asesor



Dr. Rubén Morales Menéndez
Sinodal



Dr. Luis E. Garza Castañón
Sinodal



Dr. Gerardo Antonio Castañón Ávila
Director de las Maestrías en Electrónica y Automatización de la DMTI
Mayo de 2011

Optimización de Parámetros de Corte y Detección de Desgaste en
Herramienta de Corte para un Proceso de Mecanizado a Alta Velocidad
utilizando Redes Neuronales y Algoritmos Genéticos.

POR:

Ricardo Sánchez Rubio Hernández

TESIS

Presentada al Programa de Graduados en Mecatrónica y
Tecnologías de Información

Este trabajo es requisito parcial para obtener el grado de Maestro
en Ciencias con Especialidad en Automatización

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY

Mayo de 2011

A mis padres, Ricardo y Lupita, a mis hermanas y hermanos, Diana, Lorena, Oliver y Fredy
y a mis sobrinos, Carlitos, Alex e Isabella, por ser la mejor familia que pude haber pedido.

Gracias.

AGRADECIMIENTOS

Agradezco a Dios por el valioso regalo de la vida, y por poner en mi camino a todas las personas que contribuyeron a la realización de esta tesis.

Gracias a mis padres por su apoyo incondicional a lo largo de mi formación académica, y por tener siempre fe en mí.

Gracias al Dr. Antonio Vallejo, por su instrucción y guía, y sobre todo por el alto nivel de compromiso que adquirió con un servidor para poder finalizar este trabajo de investigación a su debido tiempo, a pesar de la distancia.

Gracias al Dr. Rubén Morales y al Dr. Luis Eduardo Garza por su tiempo y apoyo como sinodales de esta tesis.

Y por último, gracias a mis compañeros de maestría y amigos, porque hicieron de esta etapa de mi vida una experiencia sobresaliente en todos los sentidos.

ÍNDICE

1. CAPÍTULO 1

INTRODUCCIÓN.....1

- 1.1. Motivación..... 1
- 1.2. Definición del problema..... 2
- 1.3. Objetivos de la Investigación..... 4
- 1.4. Metodología..... 4
- 1.5. Resumen de Capítulos.....5

2. CAPÍTULO 2

ESTADO DEL ARTE.....6

- 2.1. Conceptos del Proceso de Maquinado..... 6
- 2.2. Rugosidad Superficial.....8
- 2.3. Condición de Desgaste en la Herramienta de Corte (CTWC)..... 10
- 2.4. Antecedentes de inteligencia Artificial.....11
 - 2.4.1. Basado en la Teoría de Maquinado.....11
 - 2.4.2. Investigación Experimental.....11
 - 2.4.3. Diseño de Experimentos..... 12
 - 2.4.4. Inteligencia Artificial..... 12

3. CAPÍTULO 3

EXPERIMENTACIÓN..... 19

- 3.1. Instalación.....19
- 3.2. Datos Experimentales..... 21

4. CAPÍTULO 4

MODELOS DE ANN..... 25

- 4.1. Definición de una Red Neuronal.....25
- 4.2. Consideraciones Generales.....26

4.2.1.	Determinación del Número de Neuronas en la Capa Oculta.	26
4.2.2.	Algoritmos de Entrenamiento.	26
4.2.3.	Normalización de los Datos.	27
4.2.4.	Funciones de Activación.	27
4.3.	Descripción de los Modelos de ANN utilizados.	29
4.3.1.	Modelo Pre-Proceso.	29
4.3.2.	Modelo En-Línea.	33
4.3.3.	Modelo de Detección de CTWC.	36
5.	CAPÍTULO 5	
	OPTIMIZACIÓN DE LA RUGOSIDAD SUPERFICIAL.	39
5.1.	Concepto de Algoritmo Genético.	39
5.2.	Optimización de los Parámetros de Maquinado.	41
6.	CAPÍTULO 6	
	ANÁLISIS DE RESULTADOS.	44
6.1.	Resultados y Validación de Modelo de ANN Pre-Proceso.	44
6.2.	Resultados y Validación de Modelo de ANN En-Línea.	50
6.3.	Resultados y Validación de Modelo de ANN en Detección de CTWC.	50
6.4.	Resultados de la Optimización.	52
7.	CAPÍTULO 7	
	CONCLUSIONES Y TRABAJO FUTURO.	60
	APÉNDICES	
	APÉNDICE A Resultados para Modelos de ANN.	66
	APÉNDICE B Datos para Experimentación.	82
	REFERENCIAS.	83

ÍNDICE DE TABLAS

Tabla 2.1. Diferentes acabados de Ra y su costo de obtención.	9
Tabla 2.2. Condiciones de desgaste en la herramienta de corte.	10
Tabla 2.3. Síntesis de investigaciones en las áreas de predicción de Ra mediante el uso de ANN.	15
Tabla 2.4. Síntesis de investigaciones en las áreas de predicción de Ra y su optimización.	18
Tabla 3.1. Características del material de trabajo para maquinado.	20
Tabla 3.2. Características de los sensores instalados en el centro de maquinado CNC.	22
Tabla 3.3. Niveles factoriales para los parámetros de corte en la experimentación.	22
Tabla 3.4. Experimentos definidos para la condición Nueva en la herramienta de corte, con los valores de Ra en las dos secciones donde se midió.	24
Tabla 4.1. Resultados en la detección de CTWC utilizando señales acústicas de la pieza de trabajo y del husillo.	38
Tabla 5.1. Evaluación de una población para función de maximización de “1s”.	40
Tabla 6.1. Indicadores de desempeño para la estructura 5x10x1 RPROP en las cuatro condiciones de desgaste.	44
Tabla 6.2. Comparación del MSE de validación entre dos estructuras de ANN.	47
Tabla 6.3. Resultados para validación con nuevos experimentos de Modelo ANN En-Línea.	50
Tabla 6.4. Resultados para validación con nuevos experimentos de modelo ANN de CTWC.	51
Tabla 6.5. Optimización del Experimento #1.	53
Tabla 6.6. Optimización del Experimento #2.	55
Tabla 6.7. Optimización del Experimento #3.	55
Tabla 6.8. Optimización del Experimento #4.	56

Tabla 6.9. Optimización del Experimento #5.	57
Tabla 6.10. Optimización del Experimento #6.	57
Tabla 6.11. Optimización de un Experimento con datos nuevos en condición de herramienta Nueva.	58
Tabla 6.12. Optimización de un Experimento con datos nuevos en condición de herramienta Semi-Desgastada.	59

ÍNDICE DE FIGURAS

Figura 1.1. Parámetros de corte óptimos contra limitaciones [Tönshoff et al, 1988].	3
Figura 2.1. Centro de maquinado vertical.	7
Figura 2.2. a) Fresado periférico. b) Fresado de concordancia.	7
Figura 2.3. Valor aritmético de Ra.	9
Figura 3.1 Centro de maquinado HS-1000 Kondia.	19
Figura 3.2. Herramientas de corte.	20
Figura 3.3. Sistema de adquisición de datos en el centro de maquinado.	21
Figura 3.4. Medición de Ra en material de trabajo para geometría cóncava.	23
Figura 3.5: Evaluación de la rugosidad superficial.	23
Figura 4.1. Valores de Ra en experimentos, con los dos tipos de normalización.	28
Figura 4.2. Funciones de transferencia típicas en una ANN.	28
Figura 4.3. Modelo general de ANN para el caso Pre-Proceso.	30
Figura 4.4 Valor promedio y dispersión de datos para CF de evaluación en las estructuras Pre-Proceso.	31
Figura 4.5. Valor promedio y dispersión de datos para CF de evaluación en las estructuras Pre-Proceso con RPROP.	32
Figura 4.6. Fase de entrenamiento para la ANN utilizando RPROP y una estructura 5x10x1.	32
Figura 4.7. Fase de evaluación para la ANN utilizando RPROP y una estructura 5x10x1.	33
Figura 4.8. Estructura general para el modelo de predicción En-Línea.	34
Figura 4.9. Distribución de los sensores de medición de señales del proceso en el centro de maquinado.	35
Figura 4.10. Valor promedio y dispersión de datos para CF de evaluación en estructuras ANN En-Línea.	36

Figura 4.11. Propuesta de estructura para detección de condición de desgaste en herramienta de corte.	37
Figura 5.1. Cruce entre dos individuos en un AG.	40
Figura 5.2. Diagrama de flujo para la ejecución de un AG.	41
Figura 5.3. Diagrama de flujo representando la función objetivo.	42
Figura 5.4. Secuencia usada en el programa de optimización con AGs.	43
Figura 6.1. Valor promedio y dispersión de datos para CF de evaluación para estructuras en condición Nueva y Semi-Nueva.	45
Figura 6.2. Valor promedio y dispersión de datos para CF de evaluación para estructuras en condición Semi-Desgastada y Desgastada.	45
Figura 6.3. Fase de evaluación en modo Pre-Proceso con condición de desgaste Nueva. .	46
Figura 6.4. Fase de evaluación en modo Pre-Proceso con condición de desgaste Semi-Nueva.	46
Figura 6.5. Fase de evaluación en modo Pre-Proceso con CTWC Semi-Desgastada.	46
Figura 6.6. Fase de evaluación en modo Pre-Proceso con CTWC Desgastada.	47
Figura 6.7. Validación de la predicción de Ra para la Nueva condición de herramienta. .	48
Figura 6.8. Validación de la predicción de Ra para la condición de herramienta Semi-Nueva.	48
Figura 6.9. Validación de la predicción de Ra para la condición de herramienta Semi-Desgastada.	49
Figura 6.10. Validación de la predicción de Ra para la condición de herramienta Desgastada.	49
Figura 6.11. Validación de la predicción de Ra para proceso En-Línea con experimentos nuevos.	51
Figura 6.12. Validación de la detección de CTWC con experimentos nuevos.	52
Figura 6.13. Representación gráfica de la primera corrida del AG del Experimento #1 para la condición Nueva.	53

Figura 6.14. Representación gráfica de la tercera corrida del AG en el Experimento #1 para la condición de Semi-Nueva.54

Figura 6.15. Representación gráfica de la segunda corrida de AG en el Experimento #1 para la condición Desgastada. 54

SIMBOLOGÍA

SÍMBOLO	DESCRIPCIÓN
<i>ae</i>	Profundidad radial de corte
<i>AG</i>	Algoritmo Genético
<i>ANN</i>	Red Neuronal
<i>CF</i>	Factor de Correlación
<i>CNC</i>	Control Numérico por Computadora
<i>Curv</i>	Curvatura de la geometría en la pieza
<i>Dtool</i>	Diámetro de la herramienta
<i>fz</i>	Avance por diente
<i>HB</i>	Dureza Brinell
<i>HSM</i>	Maquinado a Altas Velocidades
<i>MFCC</i>	Cepstrales de Frecuencia de Mel
<i>MSE</i>	Error medio cuadrático
<i>Ra</i>	Valor aritmético de la Rugosidad Superficial
<i>RSM</i>	Metodología de Superficie de Respuesta

RESUMEN

Los procesos de maquinado a altas velocidades (HSM) presentan ventajas cuantitativas y cualitativas con respecto a los procesos de maquinado convencionales. Este tipo de maquinado es ampliamente utilizado en las industrias aeronáutica y automotriz, ya que se pueden maquinar piezas con mejor calidad y más rápidamente. Sin embargo, para poder aprovechar la capacidad productiva de estos centros de maquinado, se necesitan de manuales que permitan seleccionar los parámetros óptimos para determinado material. Actualmente estos manuales no existen, por lo que la selección de parámetros de corte se basa en la experiencia del operador, y esto ocasiona un incremento considerable de los costos, baja producción y elevación de tiempo de maquinado. Por esta razón es necesario el desarrollo de modelos del proceso de maquinado que permitan establecer parámetros de corte óptimos.

En el presente trabajo de investigación se aplican técnicas de Inteligencia Artificial para lograr este objetivo. Mediante el uso de Redes Neuronales se modela un proceso de fresado HSM, y con Algoritmos Genéticos se optimizan los parámetros de corte para lograr una mejor calidad en la pieza. Esto se hizo mediante la obtención de datos experimentales para poder entrenar los modelos de Redes Neuronales, y después la programación del Algoritmo Genético en un software computacional.

Como aportaciones de esta investigación se mencionan:

- El desarrollo de un modelo Pre-Proceso que puede predecir el valor de Rugosidad Superficial (Ra) en cada una de las condiciones de desgaste en la herramienta de corte con gran exactitud. Este modelo se utiliza antes de empezar el proceso de maquinado en un HSM.
- Se desarrolló un modelo En-Línea que permite la predicción de Rugosidad Superficial tomando en cuenta cualquier estado de desgaste en la herramienta de corte, así como también otro modelo de detección de este estado de la herramienta, con un alto grado de confiabilidad. Este modelo puede utilizarse en el momento del maquinado, para monitorear el valor de Ra constantemente.
- Se desarrolló también un Algoritmo Genético con una nueva función objetivo para optimizar los parámetros de corte del maquinado, utilizando los modelos de Pre-proceso.

CAPÍTULO 1

INTRODUCCIÓN

El mecanizado a altas velocidades (High Speed Machining) representa una solución a la demanda incremental de productos de industrias especializadas, como la automotriz y la aeronáutica. Así mismo, la aparición de nuevas tecnologías y avances en los sistemas de control de un CNC (Control Numérico por Computadora) permiten un diseño inteligente en el proceso de maquinado. Características como: predicción del acabado superficial en operaciones, identificación de la condición de desgaste de herramienta de corte, adquisición de datos, inferencia de información incompleta, entre otras, deben ser relevantes en el diseño de sistemas de monitoreo para maquinado, dando robustez y exactitud a procesos que así lo requieren, como es el caso de HSM.

1.1. Motivación

El HSM es una tecnología moderna que mejora varios aspectos de la manufactura en comparación a un maquinado convencional, entre los que están:

- Remoción de material a altas velocidades.
- Reducción de los tiempos de producción.
- Disminución de las fuerzas de corte.
- Menor distorsión de las piezas maquinadas.
- Incremento en la precisión del maquinado.

Su uso dentro de diferentes áreas en la industria va dirigido hacia los siguientes sectores productivos de la manufactura:

- La primera categoría corresponde al mecanizado de partes de aluminio en la industria automotriz, en partes pequeñas para computadoras y dispositivos médicos. En esta categoría se necesita la remoción rápida de material debido a que los procesos tecnológicos para su manufactura involucran demasiadas operaciones de mecanizado.
- La segunda categoría corresponde a la industria aeronáutica que involucra remover grandes cantidades de material de piezas de aluminio.
- El tercer sector es la industria de moldes, la cual requiere de excelentes acabados superficiales en materiales de gran dureza. En este sector es importante maquinar con rapidez y exactitud.

De esta manera, se observa una necesidad de lograr incrementar la velocidad y exactitud del proceso de maquinado, pero sin decremento de la calidad en la pieza de trabajo, o si es posible hasta mejorarla. Este objetivo ha sido tema de una gran cantidad de trabajos de investigación, donde se busca fusionar las innovaciones en Inteligencia Artificial (IA) con el proceso de maquinado.

De acuerdo a [Nacsa, 2001], algunos de los requerimientos futuros de una CNC, con el uso de técnicas de IA, son: la generación En-Línea de la trayectoria de maquinado basada en modelos, selección automática de parámetros de operación y de herramienta, selección En-Línea de algoritmos de control, y detección y corrección del desgaste y fractura de la herramienta de corte.

Existen diversas técnicas de IA que ya se utilizan en la investigación del maquinado inteligente, entre estas resaltan las siguientes:

- Lógica difusa (fuzzy) en el control de algunos parámetros de operación (velocidad de corte, profundidad de corte, velocidad de avance), independientemente de la herramienta de corte y la pieza de trabajo.
- Redes Neuronales y reglas difusas en los algoritmos de control de un CNC.
- Planeamiento óptimo de trayectoria, corrección en tiempo real mediante Cadenas de Markov.
- Administración del tiempo de vida de la herramienta y otras partes de la máquina utilizando Redes Neuronales en conjunción con Algoritmos Genéticos.

Con lo anterior, es evidente que el empleo de métodos Inteligentes tiene una gran área de oportunidad en el desarrollo de sistemas de control y supervisión en procesos de maquinado.

1.2. Definición del Problema

Un proceso de maquinado HSM tiene la capacidad de producir piezas con rapidez y alta calidad, sin embargo, para que esto suceda se necesita de una correcta configuración. De acuerdo a [Zuperl, 2006], la selección óptima de parámetros de maquinado es un elemento clave para la operación eficiente. Los parámetros se seleccionan usualmente antes del maquinado, de acuerdo a la experiencia del operador y los manuales del maquinado, en sistemas de maquinado tradicionales. Sin embargo, esto no es posible para un HSM.

Para prevenir daños y evitar fallas en el maquinado, las condiciones de operación se programan de una manera conservadora (Figura 1.1). La mayoría de las operaciones de corte se realizan con datos de corte recomendados, desaprovechando un rango grande de los valores de avance y velocidad de corte. Esto causa operaciones costosas, ya que las máquinas trabajan con parámetros conservadores. Los parámetros de corte óptimos, a donde pertenece este trabajo, tiene como limitación la falta de datos técnicos, basándose muchas veces en la experiencia de un operador.

Por último, se tienen los datos de corte óptimos globales, aprovechando al máximo las características de la máquina. Sin embargo, las dificultades se refieren a limitantes físicas de la máquina

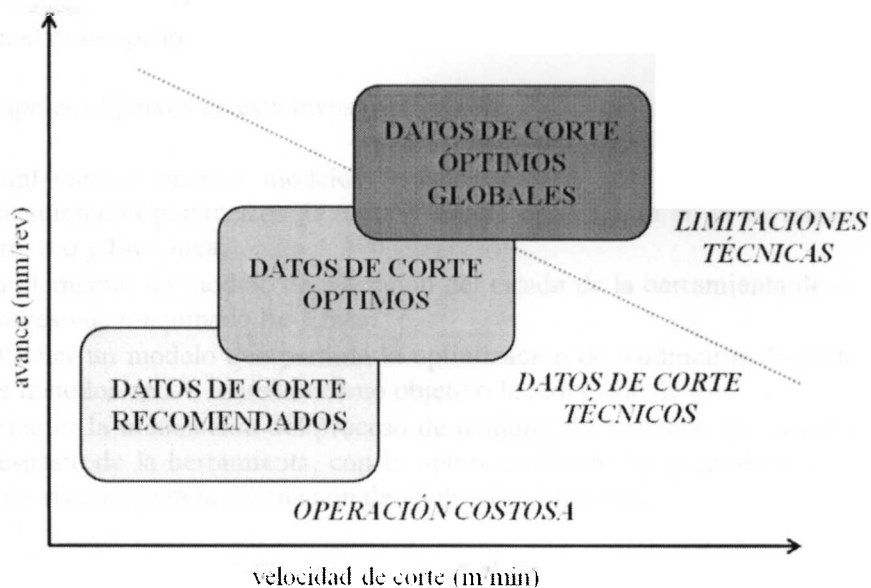


Figura 1.1. Parámetros de corte óptimos contra limitaciones [Tönshoff et al, 1988].

Para un proceso de maquinado convencional, existe un conocimiento especializado en parámetros de maquinado para la mayoría de los materiales que se utilizan en la industria. Sin embargo, para un HSM la información no es extensa, lo que da a lugar a que la operación se haga en base a la experiencia del operador.

Los parámetros de corte basados en estimaciones tienen un impacto directo en la economía del corte de metales. Costos grandes de operación, baja productividad y baja calidad del producto son resultado de condiciones no óptimas.

La calidad de un producto maquinado en la mayoría de los procesos de corte de metal se puede medir con la Rugosidad Superficial (Ra). Este es generalmente aceptado como indicador de calidad, y requiere inspección continua.

En la actualidad, es necesario desarrollar modelos del proceso de maquinado, que permitan el monitoreo y la predicción de Ra con exactitud, de manera que se puedan seleccionar los parámetros de maquinado óptimos. Los mecanismos de formación de Ra , así como los numerosos factores que influyen este proceso, hacen que este problema sea extremadamente difícil de abordar con métodos matemáticos, como lo explica [Bernardos, 2003]. Por lo tanto, se emplean técnicas de IA que ayuden a modelar el proceso de maquinado, así como a seleccionar parámetros óptimos y monitorear el proceso.

1.3. Objetivos de la Investigación

Esta investigación busca desarrollar modelos basados en IA para monitorear y optimizar un proceso de maquinado HSM, teniendo en cuenta la rugosidad superficial como variable que determina el desempeño del proceso.

Los principales objetivos de esta investigación son:

- Implementar nuevos modelos basados en IA para estimar el valor de Ra considerando parámetros de corte y estado de desgaste en la herramienta, en Pre-Proceso y En-Línea.
- Implementar un modelo de detección del estado de la herramienta de corte para un proceso de maquinado En-Línea.
- Diseñar un modelo que permita la optimización de parámetros de corte por medio de métodos de IA, teniendo como objetivo la reducción de Ra .
- Integrar la modelación del proceso de maquinado, tomando en cuenta el estado de desgaste de la herramienta, con la optimización de los parámetros de corte en un solo sistema para la simulación de un proceso En-Línea.

1.4. Metodología

Para alcanzar los objetivos planteados, es necesario llevar la investigación mediante pasos sistematizados y definidos. Para esto, se propone lo siguiente:

- Investigación bibliográfica sobre antecedentes en la predicción de Ra utilizando métodos de IA, específicamente Redes Neuronales.
- Programación de la ANN propuesta, obtener resultados experimentales en simulación.
- Análisis de los resultados, cambios en la estructura de la ANN hasta obtener el mejor desempeño.
- Propuesta de la estructura de ANN para detectar condición de desgaste en la herramienta de corte.
- Experimentación en simulación y análisis de resultados en los modelos ANN.
- Investigación bibliográfica sobre optimización de parámetros de maquinado utilizando Algoritmos Genéticos.
- Configuración de parámetros del AG para obtener el desempeño deseado.
- Experimentación de la optimización y análisis de resultados con los AGs.
- Integración de los elementos de modelación del proceso de maquinado mediante ANNs, la detección de condición de desgaste en herramienta de corte y optimización de parámetros mediante AGs en un sistema de monitoreo para fresado periférico en HSM.

1.5. Resumen de Capítulos

- El Capítulo 2 aborda una síntesis de los trabajos relevantes en predicción de *Ra* utilizando Redes Neuronales, optimización de parámetros de maquinado por medio de Algoritmos Genéticos, y fundamentos teóricos de Rugosidad Superficial.
- En el Capítulo 3 se describe la experimentación realizada para recabar los datos a utilizarse para desarrollar los modelos, así como el centro de maquinado y diversos sensores que se utilizaron.
- En el Capítulo 4 se describen las características de un modelo de Redes Neuronales, así como la estructura propuesta para modelar el proceso de maquinado.
- El Capítulo 5 trata acerca de la teoría de Algoritmos Genéticos, así como la optimización de los parámetros de corte por medio de estos.
- En el Capítulo 6 se analizan y discuten los resultados obtenidos, tanto de la predicción de *Ra* por medio de Redes Neuronales e identificación de condición de desgaste en la herramienta, como de la optimización de parámetros de corte por Algoritmos Genéticos.
- El Capítulo 7 trata de las principales conclusiones tanto en los modelos de predicción como en la optimización. Finalmente, se sugieren aspectos para el trabajo futuro relacionado con el tema desarrollado.

CAPÍTULO 2

ESTADO DEL ARTE

En este capítulo se aborda la teoría del proceso de maquinado a altas velocidades y rugosidad superficial, así como un resumen de los trabajos más relevantes en el campo de la optimización de parámetros de corte a través de Redes Neuronales y Algoritmos Genéticos.

2.1. Conceptos del Proceso de Maquinado

El fresado es un proceso muy importante en la industria del metal, teniendo numerosas aplicaciones en distintas áreas; entre ellas, la automotriz y la aeronáutica. Un tipo de fresado versátil es el fresado vertical, ya que este puede trabajar en superficies horizontales, verticales e inclinadas; así como realizar operaciones de taladrado, escariado y barrenado. Este tipo de fresado es el utilizado en la recolección de datos sobre el proceso para realizar la experimentación.

En adición al tipo de orientación que puede tener el husillo en una máquina de fresado, se considera un modo de operación llamado fresado periférico, en el que la superficie maquinada es generada por dientes localizados en la periferia de la herramienta. Este tipo de fresado periférico se llama “end milling”, y se puede realizar en centros de maquinado como el mostrado en la Figura 2.1. Esto se refiere al tipo de herramienta de corte, el cual es de un diámetro pequeño (usualmente entre 5 mm y 30 mm de diámetro) y su longitud es varias veces su diámetro. En cuanto a la dirección de la rotación del eje, se escogió el fresado en concordancia o “down milling”, donde la dirección de giro coincide con el avance de la herramienta (Figura 2.2) [Boothroyd et al, 2006]. Este tipo de fresado permite una mejor calidad en la rugosidad superficial.

Los parámetros de corte que debe programar un operador son:

- Velocidad de corte:

$$v_c = \frac{\pi \times D_{tool} \times n_t}{1000} (m/min)$$




Figura 2.1. Centro de maquinado vertical.




Figura 2.2. a) Fresado periférico. Las operaciones de fresado periférico usualmente se realizan en máquinas con el husillo en posición horizontal; sin embargo, también se pueden llevar a cabo en máquinas verticales. b) Fresado de concordancia. En este tipo de fresado el husillo rota en la dirección del avance de la pieza.

- Número de revoluciones en el husillo:

$$n_t = \frac{v_c \times 1000}{\pi \times D_{tool}} (rpm)$$

- Avance por diente:

$$fz = \frac{v_f}{n_t \times z} (mm/diente)$$

Donde D_{tool} es el diámetro de la herramienta, v_f es la velocidad de avance y z es el número de dientes en el eje.

2.2. Rugosidad Superficial

La Rugosidad Superficial es ampliamente usada como un indicador de calidad en un producto, y en la mayoría de los casos es un requerimiento técnico para las piezas. La rugosidad obtenida durante un proceso de maquinado puede considerarse como la suma de dos efectos independientes:

- La R_a “ideal”, resultante de la geometría de la herramienta y la velocidad de avance.
- La R_a “natural”, resultante de las irregularidades en la operación de corte.

La Rugosidad Ideal representa el mejor acabado posible que se puede obtener con determinada herramienta y sólo se puede acercar a este resultado en condiciones ideales; es decir, si se elimina el castaño, la formación de bordes y las inexactitudes en el movimiento de la máquina. En la práctica, es casi imposible alcanzar tales condiciones, y normalmente la rugosidad natural constituye una gran porción de la rugosidad real.

La Rugosidad Natural es causada por los siguientes procesos en el maquinado:

- Formación de bordes en el material.
- Castaño o vibraciones en la herramienta.
- Errores en el movimiento de la máquina.
- Irregularidades en el mecanismo de avance.
- Defectos en la estructura del material de trabajo.
- Creación de viruta en el maquinado de materiales frágiles o quebradizos.
- Fisuras en el material de trabajo cuando se cortan metales dúctiles a bajas velocidades.
- Daño en la superficie, causado por factores como el flujo de rebaba.

Para propósito de análisis y comparación cuantitativa, es útil expresar la rugosidad de superficies maquinadas en términos de un solo factor. El índice que es más comúnmente usado es el valor aritmético medio R_a (Figura 2.3). La ecuación que define la R_a se expresa como sigue:

$$R_a = \frac{1}{L} \int_0^L |z(x)| dx$$




Figura 2.3. Valor aritmético de Ra . La forma de determinar este valor es creando una línea paralela a la dirección general de la superficie, que divide la superficie en tal forma que la suma de las áreas formadas sobre la línea es igual a la suma de las áreas formadas debajo de la línea. La Ra se expresa como la suma de los valores absolutos de las áreas sobre y debajo de la línea, dividida por la longitud de muestra.

Los diferentes acabados que generalmente se utilizan en la industria del maquinado de metales comprenden desde la clase espejo hasta la clase rugoso y limpio, como se muestra en la Tabla 2.1.

Tabla 2.1. Diferentes acabados de Ra y su costo de obtención. Esta investigación busca diseñar un sistema que permita optimizar la obtención de Ra para acabados de tipo Espejo y Pulido.

Clase	Ra (μm)	Costo relativo de obtención
Espejo	0.10	40
Pulido	0.20	35
Ground	0.40	25
Terso	0.80	18
Fino	1.60	13
Semifino	3.2	9
Medio	6.3	6
Semirugoso	12.5	4
Rugoso	25	2
Limpio	50	1

2.3. Condición de Desgaste en la Herramienta de Corte (CTWC)

El desgaste en la herramienta CTWC (Cutting Tool Wear Condition) se define como la pérdida gradual del material de la herramienta en las zonas de contacto con la pieza de trabajo. Esto tiene un impacto directo en las dimensiones finales del producto, el acabado superficial y la integridad superficial.

Se han realizado esfuerzos en parametrizar las condiciones de desgaste, entre ellas el trabajo de [Vallejo et al., 2005]. En la investigación mencionada, el desgaste en el flanco de la herramienta (VB) se modeló con un enfoque de fusión de sensores, midiendo las señales de emisión acústica, y caracterizándolas mediante un proceso conocido como Coeficientes Cepstrales en las Frecuencias Mel (Mel Frequency Cepstrum Coefficients, MFCC). Este conjunto de operaciones consiste en lo siguiente:

1. Se selecciona un segmento pequeño de la señal vibratoria.
2. Se realiza una transformada discreta de Fourier.
3. La magnitud del espectro de energía se transforma a una escala logarítmica.
4. La escala de frecuencia real se asigna a la escala de frecuencia percibida.
5. Un filtro pasa bajas se aplica para suavizar el espectro escalado.
6. Finalmente se obtienen los MFCC utilizando la inversa de la transformada de Fourier.

Los estados de la herramienta de corte consideran la vida útil de la herramienta desde la condición Nueva hasta la Desgastada, como se muestra en la Tabla 2.2.

Tabla 2.2. Condiciones de desgaste en la herramienta de corte. Se consideraron cuatro estados diferentes dependiendo del desgaste en el flanco de la herramienta de corte.

Condición de la herramienta de corte	Desgaste en el flanco (mm)
Nueva	$0 \leq VB \leq 0.08$
Semi-Nueva	$0.08 \leq VB \leq 0.1$
Semi-Desgastada	$0.1 \leq VB \leq 0.3$
Desgastada	$0.3 \leq VB \leq 0.5$

2.4. Antecedentes en Inteligencia Artificial

La predicción de Ra en el maquinado ha sido objeto de un extenso número de investigaciones, tanto por su importancia en la aplicación industrial, como por los enfoques diferentes con los que se puede abordar este problema.

De acuerdo a [Zain et al, 2008], se necesitan dos fases en la optimización de los parámetros de maquinado en un proceso, las cuales son el modelado y la optimización. La primera fase implica el desarrollo de modelos para predecir los valores de respuesta o medida de desempeño como el valor de Ra . Esto usualmente significa modelar el proceso de maquinado. La segunda fase es la determinación de las condiciones de optimización para la función objetivo.

En [Bernardos et al, 2003] se presenta una compilación de los diferentes enfoques en la predicción de Ra , los cuales están divididos en cuatro grupos, los cuales se describen a continuación.

2.4.1. Basado en la Teoría de Maquinado

Esta categoría pone énfasis en ciertos aspectos de la teoría de maquinado, tales como: cinemática del proceso, propiedades de la herramienta de corte, mecanismo de formación de rebaba, etc. El diseño por computadora (CAD) se utiliza para construir un modelo capaz de simular la creación del perfil de una superficie maquinada, y de esta forma visualizar la topografía de la superficie y evaluar la rugosidad.

Se pueden incluir parámetros adicionales, tales como vibraciones, en un esfuerzo por representar el fenómeno con mayor exactitud. El inconveniente del método es que no se consideran muchos otros factores que contribuyen a la formación de la rugosidad, por ejemplo, el desgaste en la herramienta de corte o ciertos fenómenos térmicos.

2.4.2. Investigación Experimental

El enfoque experimental puede pensarse como el método más “obvio”. Consiste en realizar experimentos con los factores que se consideran los más importantes, y los resultados que se obtienen se usan para investigar el efecto de cada factor en la calidad observada. Con frecuencia se utiliza un análisis de regresión para construir modelos basados en los datos experimentales.

La intuición del investigador y su percepción toman una gran parte en este enfoque, pero es necesaria también una alta comprensión del fenómeno examinado. La principal

ventaja de este método es que no es difícil de implementar y puede producir buenos resultados. Sin embargo, las conclusiones pueden tener poca o nula aplicabilidad.

2.4.3. Diseño de Experimentos

Consiste en un método sistemático de planeamiento de experimentos, recolección y análisis de datos con un uso casi óptimo de los recursos disponibles. Las técnicas más utilizadas para el problema de predicción de *Ra* son la metodología de superficie de respuesta (RSM) y las técnicas de Taguchi para el Diseño de Experimentos (DoE).

2.4.4. Inteligencia artificial

La Inteligencia artificial se implementa por medio de Redes Neuronales (ANN), Algoritmos Genéticos (AG), lógica difusa y sistemas expertos. Las ANNs y AGs se basan en simular la manera en la que el ser humano procesa información y toma decisiones. Los ANNs se han usado para simular sistemas complejos, encontrando patrones entre entradas y salidas de datos. Dentro de la categoría de IA se han realizado las siguientes contribuciones relevantes en la predicción del *Ra* por medio de ANN:

En [Tsai et al, 1999], un acelerómetro y un sensor de proximidad se emplearon para recolectar datos sobre vibración y rotaciones, en un proceso de fresado convencional. La información se utilizó como un parámetro, promedio de vibraciones por revolución (VAPR), junto con la velocidad del husillo, la velocidad de avance y la profundidad de corte. Estos 4 parámetros se usan como entradas en una ANN.

El diseño experimental consideró 4 valores para la velocidad del husillo (750, 1000, 1250 y 1500 rpm), cuatro valores para la velocidad de avance (6, 12, 18 y 24 plg/min), y tres valores de profundidad de corte (0.01, 0.03 y 0.05 plg), lo que dio lugar a 48 diferentes experimentos. Se probaron diferentes estructuras de ANN con retro propagación, utilizando de 1 a 8 neuronas en la capa oculta, encontrando que las más relevantes fueron 4x5x1 para una capa oculta, y 4x7x7x1 para dos capas ocultas. La determinación del número de neuronas en la capa oculta se obtuvo a prueba y error, y los números de neuronas que se probaron se escogieron sin fundamento aparente. La raíz del error cuadrático medio (RMS) se utilizó como indicador del desempeño para las estructuras. En la etapa de entrenamiento, el error fue de 0.00608, y en evaluación de 0.00490 para la estructura 4x5x1. Para el modelo 4x7x7x1, el RMS en entrenamiento fue de 0.00084, y en evaluación, de 0.00094.

El autor realizó una serie de nuevos experimentos para evaluar la habilidad predictiva de los modelos de ANN, con valores de parámetros de corte diferentes a los antes utilizados. La velocidad de avance cambió a 9, 15 y 21 plg/min, mientras que las otras

variables permanecieron con los valores anteriores. La exactitud de predicción fue de 92.07% para la estructura 4x5x1, y de 96.07% para la estructura 4x7x7x1.

En [Bernardos et al, 2002] se analizó un proceso de fresado para predecir la *Ra*. Primeramente se consideraron 9 factores con distintos valores, basados en los manuales de seguridad de la máquina: 0.25, 0.75 y 1.2 (mm) para profundidad de corte; 0.08, 0.14 y 0.3 (mm/diente) para avance por diente; 300, 500 y 700 (m/min) para velocidad de corte; 30, 60 y 100% de profundidad radial de corte, desgaste pequeño o promedio de la herramienta de corte, una variable binaria para el uso de fluido de corte, y 3 componentes de la fuerza de corte (*X*, *Y* y *Z*). La fuerza de corte fue medida montando la pieza de trabajo en un dinamómetro Kistler 9257A. Debido a que se consideraron 9 factores con 2 valores por cada factor, y 3 estructuras diferentes de ANN, se tenían 1536 modelos diferentes para probar. Para reducir el número de estructuras a evaluar se usó un arreglo ortogonal (OA) basado en el diseño de experimentos de Taguchi (DoE), y 91 modelos se seleccionaron como representativos del grupo completo.

Se utilizó un modelo de ANN con el algoritmo de Levenberg-Marquardt para entrenamiento, con estructuras de $nx2x1$, $nx3x1$, $nx5x1$, donde *n* representa el número de factores utilizados como entrada. Los números de neuronas en la capa oculta que se utilizaron en las pruebas se seleccionaron sin una justificación. Los datos experimentales se dividieron para entrenamiento y evaluación; de un total de 27 grupos de datos, 18 (66.67%) se usaron para entrenamiento, 4 (14.81%) para validación y 5 (18.52%) para evaluación. El error cuadrático medio (MSE) se utilizó como indicador de desempeño. El mejor modelo encontrado fue una estructura 5x3x1, donde los factores de entrada fueron el avance por diente, la componente *X* de la fuerza de corte, profundidad de corte, profundidad radial de la herramienta de corte, y el uso de fluido de corte. El MSE que se obtuvo fue de 1.86%.

[Liu et al, 2006] presenta un modelo de ANN con tres capas, y con retro propagación, utilizado para simular un fresado HSM. Las entradas que se consideraron son la velocidad de corte, velocidad de avance, y la profundidad axial/radial de corte. Mediante experimentación se obtuvieron 32 grupos de datos de entrada/salida. Se realizó un análisis de componentes principales para probar la correlación entre los datos de entrada con los de salida. El análisis mostró que los parámetros seleccionados son responsables del 97% de la variabilidad en la *Ra*. El autor propuso 4 diferentes redes, 4x9x1, 4x9x9x1, 4x12x1 y 4x12x12x1. La selección del número de neuronas que se probaron en la capa oculta no se justificó. Una función de transferencia lineal se usó para la capa de salida, y una función tangente sigmoideal en la capa oculta.

Los datos de entrenamiento corresponden a dos terceras partes del total, y los datos de evaluación al tercio restante. Un coeficiente de correlación se escogió como indicador de desempeño. El mejor modelo encontrado consiste en una estructura 4x9x9x1 con un algoritmo de aprendizaje Levenberg-Marquardt en conjunción con un esquema de regularización Bayesiano. El coeficiente de correlación para la etapa de entrenamiento fue de 0.968, y para el total de datos 0.973.

En [Vallejo et al, 2009] se desarrolla una estructura de ANN basada en parámetros de corte y variables de proceso, para predecir la Ra en HSM. Este trabajo incorpora sensores para predecir la condición de desgaste de la herramienta de corte, así como otros sensores instalados en el centro de maquinado CNC para obtener las variables de proceso.

Un procesamiento basado en MFCC se realiza en las señales adquiridas, y el resultado se utiliza como variables de proceso en las estructuras de ANN. Después de un análisis, cinco factores de corte se determinaron como relevantes: avance por diente, diámetro de la herramienta de corte, profundidad radial de corte, dureza del material de trabajo, y la curvatura geométrica de maquinado. Una contribución importante fue la caracterización del CTWC, dividido en cuatro estados de la herramienta de corte: Nueva, Semi-nueva, Semi-desgastada y Desgastada. Se consideraron 3 configuraciones diferentes de ANN, y en adición a los parámetros de corte, se utilizaron las fuerzas de corte de los ejes X y Y , y las señales de vibración en la pieza de trabajo como entradas de la ANN. Como salida se obtuvieron diferentes caracterizaciones de Ra . La estructura con el mejor desempeño fue una ANN con los parámetros de corte y la fuerza en el eje Y , con estructura 12x12x1, y con un MSE de 8.48%. Como conclusión de este trabajo, el CTWC se identificó correctamente en el desarrollo experimental; la inclusión de las variables de proceso mejoró la habilidad predictiva de Ra , y como trabajo a futuro se sugiere el incorporar los resultados principales en un sistema de control supervisor.

La Tabla 2.3 presenta una síntesis de los trabajos e investigación en predicción de Ra utilizando ANNs.

Un AG es un método de búsqueda inteligente. Su funcionalidad se basa en las dinámicas de la evolución, tales como la selección natural, supervivencia del más apto, y genética. Los AGs tienen la habilidad de explotar eficientemente información pasada para especular sobre nuevos puntos de búsqueda que tengan mejor desempeño. Este tipo de algoritmo se utiliza usualmente en problemas de optimización, donde existe virtualmente un número infinito de posibles combinaciones de parámetros, para producir resultados que satisfagan ciertos objetivos.

De acuerdo a [Booker et al, 1989], un AG selecciona clasificadores de alto desempeño como “padres”, formando “hijos” por recombinación de componentes de los padres clasificadores. Los hijos reemplazan a clasificadores débiles en el sistema y entran en competencia, siendo activados y evaluados cuando sus condiciones se satisfacen. Entonces, un AG, crudamente, pero velozmente, simula la evolución de un proceso genético.

En el campo de predicción de Ra y optimización de parámetros utilizando AGs, existen varias contribuciones relevantes, las cuales se describen a continuación.

En [Palanisamy et al, 2007], un modelo matemático del tiempo de maquinado para un proceso de fresado se usó como función objetivo. Tres parámetros de corte se identificaron como variables independientes para el AG: diámetro y longitud de la herramienta de corte, velocidad del husillo y avance por diente. Para tener un enfoque realista y práctico, el rango posible de valores para la velocidad de corte y avance se limitaron por varias restricciones,

incluyendo requerimientos del acabado superficial, vida útil de la herramienta de corte, fuerza máxima de corte permitida por la rigidez de la herramienta, amplitud de la vibración en el soporte de la pieza de trabajo, el calor máximo generado por el corte, y avances y velocidades de husillo disponibles en la herramienta de maquinado. Para poder usar AGs, las variables se codificaron primero en estructuras llamadas “strings” o cadenas.

Tabla 2.3. Síntesis de investigaciones en las áreas de predicción de *Ra* mediante el uso de ANN.

Proceso de maquinado	Parámetros de corte	Señales de sensor	Desgaste de herramienta	Algoritmo de entrenamiento	Arq.	Ref.
Fresado	Vel. husillo, vel. de avance, prof. de corte.	(VAPR)	NO	Retro propagación	4x5x1 4x7x7x1	[Tsai et al, 1999]
Fresado	Prof. de corte, avance/diente, vel. de corte, profundidad radial de corte, uso de fluido.	Fuerzas en X, Y, Z	Pequeño o promedio	Levenberg-Marquardt	5x3x1	[Bernardos et al, 2002]
Fresado HSM	Vel. de corte, vel. de avance, profundidad axial y radial de corte.	NO	NO	Levenberg-Marquardt	4x9x9x1	[Liu et al, 2006]
Fresado HSM	Avance/ diente, diámetro de herramienta, profundidad radial, dureza del material, curvatura geométrica del maquinado.	Acel. en X, Y, fuerzas en X, Y	Nueva, Semi-nueva, Semi-desgastada, Desgastada	Retro propagación	12x12x1	[Vallejo et al, 2009]

Una codificación binaria fue seleccionada para representar las variables de avance por diente, profundidad axial de corte y velocidad de corte, con 8 bits por variable, con un total de longitud de cadena de 24 bits. Con la codificación, la exactitud obtenida en la solución es de 0.001 mm/diente, 0.01 mm y 0.1 m/min para las variables respectivas. Para el AG, se seleccionó una generación de 200 individuos, y las probabilidades de cruce y mutación se determinaron en 0.9 y 0.001, respectivamente. Como resultado, la *Ra* de la superficie maquinada para los parámetros optimizados estuvo dentro del límite permisible, y la fuerza de corte se mantuvo por debajo de los 500 N para mantener el desgaste de la herramienta a un mínimo y obtener una razón constante de remoción de material.

Basado en la Metodología de Superficie de Respuesta (RSM), en [Suresh et al, 2002] se desarrollaron dos modelos diferentes para la predicción de Ra en un proceso de torneado. Cuatro parámetros, velocidad, avance, profundidad de corte y radio de punta de la herramienta de corte, fueron seleccionados para la experimentación. Como el modelo de primer orden no tuvo el desempeño adecuado, se desarrolló un modelo de segundo orden, con un coeficiente de regresión múltiple de 0.801. Esta ecuación matemática fue optimizada utilizando AGs. Mediante el uso de AGs se obtuvieron valores máximos y mínimos de Ra para cierto rango de parámetros de corte.

En [Tansel et al, 2006] se utilizaron GONNS (Sistema de Redes Neuronales Genéticamente Optimizado) para realizar una optimización en dos casos de estudio de un proceso de fresado. El primer caso consistió en encontrar las condiciones de operación óptimas para mantener las fuerzas de corte en un rango deseado, mientras que la razón de remoción de material se maximizaba. El segundo caso se calculó para obtener el mejor compromiso posible entre la rugosidad de superficies en moldes maquinados y la duración del corte para acabado.

Para el modelado del proceso de maquinado, dos ANNs se utilizaron en cada caso. En el primer caso, el GONNS utilizó dos ANNs con retro propagación. La primera fue entrenada para estimar la dirección de avance de las fuerzas de corte. La segunda ANN se entrenó para estimar la razón de remoción de metal. Cada ANN tenía ocho nodos en la capa oculta. El GONNS se utilizó para maximizar la razón de eliminación de material. El tamaño de población se seleccionó como 6, el número de hijos como 1, la probabilidad de cruce como 0.2, la probabilidad de mutación como 0.1 y la probabilidad de arrastre como 0.05. Los valores óptimos se encontraron en menos de 500 iteraciones. Para el segundo caso, una ANN se entrenó para estimar la Ra , y la otra se entrenó para estimar el tiempo de maquinado. Los parámetros de AG se mantuvieron iguales que el primer caso. Como las ANNs tenían una entrada más, y el número de parámetros optimizados se duplicó, las iteraciones se incrementaron 9000 y 12000 veces. Los parámetros optimizados fueron la velocidad del husillo, avance, profundidad radial de corte y tolerancia, mientras que uno de los dos valores de desempeño se mantuvo en un rango deseado y el otro se minimizó.

En [Wang et al, 2009], un proceso de fresado HSM se optimizó para lograr una razón de eliminación de material máxima. Se realizaron experimentos de fresado en aleaciones de aluminio, utilizando un centro de maquinado con una velocidad de husillo máxima de 60000 rpm y con un avance máximo de 85m/min. El diámetro de la herramienta de corte se fijó en 4 mm. Se utilizó un método de análisis de Regresión para crear el modelo predictivo de la Ra . El modelo propuesto tuvo un promedio de ajuste de 91.04%.

La función objetivo de los parámetros de corte para el AG se definió como la razón máxima de remoción de material, en términos de la velocidad de corte, el avance por diente y la profundidad de corte. Se utilizó una codificación binaria, y la longitud total del cromosoma fue de 30 bits (6 bits para codificar el avance por diente, 16 bits para la velocidad de corte y 8 bits para la profundidad de corte). El tamaño de población se definió como 40, la probabilidad de cruce como 0.2, la probabilidad de mutación como 0.05, y se utilizaron 1000 iteraciones. Como resultado, se concluye que la razón máxima de remoción

de material se puede alcanzar en cierto rango de Ra , escogiendo los parámetros de corte correctos.

Un AG se utilizó para optimizar las condiciones de corte de un proceso de fresado con herramientas de carburo sin recubrimiento en [Zain et al, 2009]. Para el modelado del proceso, se utilizó una expresión matemática. Esta ecuación, que evalúa la Ra , se propuso como función objetivo de la solución óptima. La minimización de la función objetivo estuvo sujeta a los límites de los valores en las condiciones de corte (velocidad, avance y ángulo radial de la herramienta). Los parámetros del AG que se seleccionaron fueron el tamaño de población como 100, una razón de mutación de 1.0 y 0.8 para cruce. Como solución óptima se encontró un valor de Ra de $0.17533 \mu\text{m}$, y se obtuvo con 90 iteraciones. La técnica de AG incremento el valor de Ra por 25.7% en comparación con el mejor valor de Ra de los experimentos, y 22.4% en comparación con el resultado del modelo de Regresión.

La Tabla 2.4 presenta una síntesis de las investigaciones mencionadas sobre predicción de Ra y optimización de parámetros de maquinado utilizando AGs.

Las contribuciones propuestas en esta investigación de tesis en las áreas de predicción de Ra por medio de ANNs y optimización de parámetros de corte por medio de AGs se resumen a continuación:

- Las investigaciones presentadas utilizan sólo dos algoritmos de entrenamiento (Levenberg-Marquardt y Retro Propagación). La presente Tesis propone nuevos algoritmos para la ANN que permitan un mejor desempeño en la predicción de Ra .
- Las arquitecturas de ANN propuestas por los autores anteriores, no se menciona la forma de establecer la cantidad de neuronas en la capa oculta. Esta investigación propone la utilización de un método para determinar la cantidad óptima.
- La mayor parte de los trabajos no consideran la predicción del valor de Ra En-Línea, a comparación de esta investigación.
- La mayoría de las investigaciones mencionadas no consideran la condición de desgaste en la herramienta, y esta investigación considera cuatro condiciones diferentes.
- Para las investigaciones antecedentes, se realizó un número de experimentos máximo de 48. En este trabajo se consideraron 110 experimentos para cada una de las condiciones de desgaste en la herramienta, y de cada experimento se obtuvieron dos datos.
- Esta investigación considera el desgaste en la herramienta de corte (CTWC) en la predicción de Ra , lo que permite un mejor desempeño, y una predicción En-Línea.
- Se propone el uso de los modelos de ANN y la implementación de un AG para seleccionar los parámetros de corte óptimos en el maquinado que permitan obtener una Ra deseada.

Tabla 2.4. Síntesis de investigaciones en las áreas de predicción de *Ra* y su optimización.

Proceso de maquinado	Parámetros de corte	Modelación del proceso	Parámetros del AG	Referencia
Torneado	Vel., avance, profundidad de corte, radio de punta de la herramienta.	RSM de 2do orden	No se mencionan	[Suresh et al, 2002]
Fresado	Vel. de husillo, avance, profundidad radial de corte, tolerancia.	ANN	Población: 6 Cruce: 0.2 Mutación: 0.1 Arrastre: 0.05	[Tansel et al, 2006]
Fresado	Diámetro y longitud de la herramienta de corte, vel. del husillo, avance por diente.	Modelo matemático	Población: 200 Cruce: 0.9 Mutación: 0.001	[Palanisamy et al, 2007]
Fresado HSM	Vel. de corte, avance/diente, profundidad de corte.	RSM	Población: 40 Cruce: 0.2 Mutación: 0.05	[Wang et al, 2009]
Fresado	Velocidad de avance, ángulo radial de corte.	RSM	Población: 100 Cruce: 0.8 Mutación: 1.0	[Zain et al, 2009]

CAPÍTULO 3

EXPERIMENTACION

Esta sección aborda los aspectos técnicos de la experimentación (centro de maquinado, piezas de trabajo) realizada para obtener la información que permita modelar el proceso de maquinado. También se describen los conjuntos de datos obtenidos durante dicha experimentación.

3.1. Instalación

Los experimentos se realizaron en un centro industrial HSM HS-1000 Kondia, con un motor de 25 KW, 3 ejes, 24000 rpm como máxima velocidad de husillo y un controlador Siemens Sinumerik 840D (Figura 3.1).




Figura 3.1. Centro de maquinado HS-1000 Kondia.

Las diferentes geometrías establecidas en la experimentación permiten considerar el dominio de maquinado que pudiera presentarse en la elaboración de moldes para la industria aeronáutica y automotriz. Estas geometrías se observan en la Figura 3.2. Las características de los materiales utilizados en el proceso de maquinado se presentan en la Tabla 3.1.




Figura 3.2. Herramientas de corte (Sandvik Coromant 8, 10, 12, 14, 16 mm) y piezas de trabajo con diferentes geometrías (recto, convexo, cóncavo).

Tabla 3.1. Características del material de trabajo para maquinado.

Características	
Material	Aleaciones de aluminio (5083-H111, 6082-T6, 2024-T3, 7022-T6, 7075-T6)
Tamaño	100 x 170 x 25 mm
Geometría	Cóncavo, convexo y recto
Herramienta de corte	Sandvik Coromant de 8, 10, 12, 16 y 20 mm

En adición al centro de maquinado, se instaló un sistema de adquisición de datos, consistente de un conjunto de sensores posicionados en el husillo y en la base de la pieza de trabajo. Esto permitió el monitoreo y registro de diferentes parámetros del proceso, que a su vez mejoraron la predicción de Ra , y del desgaste en la herramienta de corte. Los tipos de sensores utilizados son los siguientes:

- Acelerómetros: Se utilizan para medir la vibración entre la pieza de trabajo y la herramienta de corte.
- Emisores acústicos: Se utilizan exitosamente para detectar desgaste en la herramienta de corte, fracturas, y calidad en la rugosidad superficial.
- Dinamómetro: Las fuerzas de corte pueden estar correlacionadas con el desgaste en la herramienta y la rugosidad superficial. La fuerza se vuelve importante en condiciones de mucho desgaste ya que es resultado de variaciones producidas por la fricción entre el flanco de la herramienta y la pieza de trabajo.

Los tipos de sensores que se instalaron en el centro de maquinado y sus características se pueden observar en la Figura 3.3, y su descripción en la Tabla 3.2.

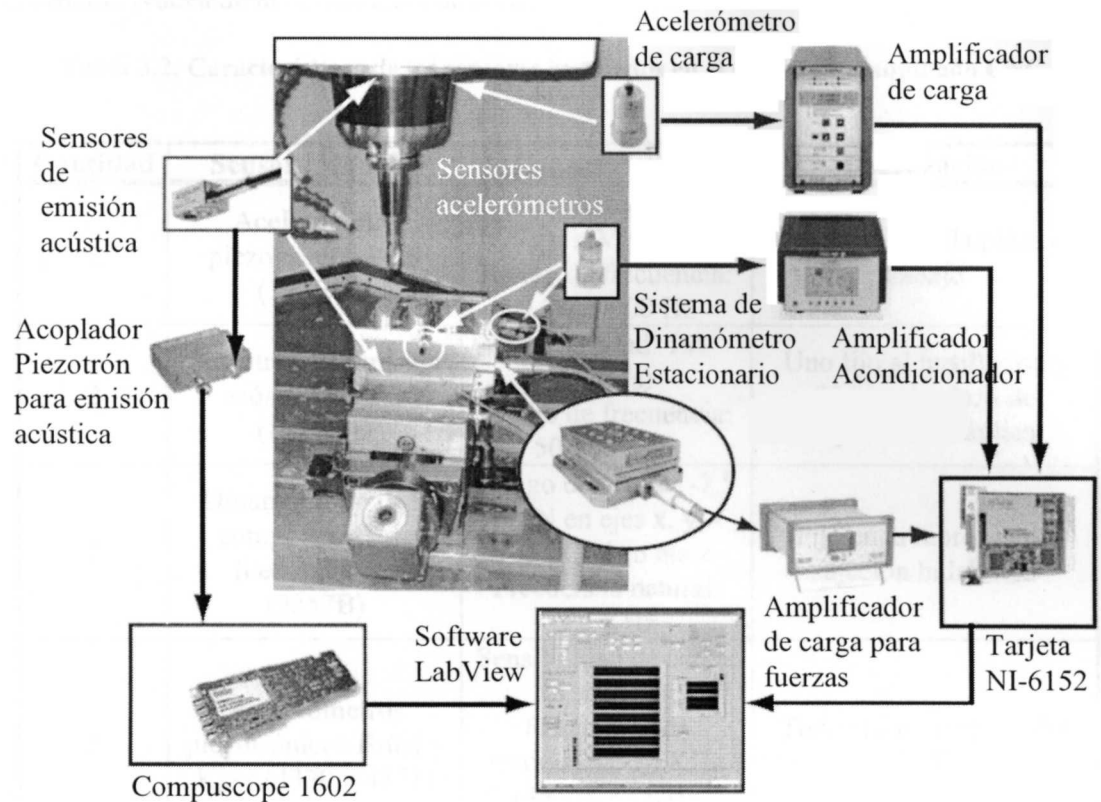


Figura 3.3. Sistema de adquisición de datos en el centro de maquinado. Se muestran los diferentes sensores (acelerómetros, emisores acústicos y dinamómetros), los amplificadores de carga y las tarjetas de adquisición. Un programa en LabView se utilizó para el control y grabación de diferentes señales del proceso durante la experimentación.

3.2. Datos Experimentales

En [Vallejo et al, 2009] se presenta el diseño de experimentos para determinar los parámetros más significantes en la variabilidad de la R_a en un proceso de fresado en HSM. Los factores más relevantes son: el avance por diente (f_z), el diámetro de la herramienta de corte (D_{tool}), la profundidad radial de corte (ae), la dureza Brinell (HB) y la curvatura de la geometría en la pieza de trabajo ($Curv$).

En la experimentación se consideraron diferentes valores para los parámetros de corte, los cuales se muestran en la Tabla 3.3. Se realizaron 110 experimentos para cada condición de desgaste en la herramienta. Sin embargo, para cada ensayo la rugosidad superficial fue obtenida en 2 lugares diferentes, tal como se muestra en la Figura 3.4. Con esto, el total de

datos para cada condición de desgaste de la herramienta fue de 220. La Tabla 3.4 al final de este capítulo muestra los 32 experimentos definidos para la caracterización de Ra con condición Nueva de la herramienta de corte.

Tabla 3.2. Características de los sensores instalados en el centro de maquinado CNC.

Cantidad	Sensor (Modelo)	Características	Localización
2	Acelerómetro piezotrónico PCB (353B04)	Sensibilidad: 10 mV/g Rango de frecuencia: 0.35-20000 Hz	Ejes X & Y en la pieza de trabajo
2	Piezotrón de emisión acústica Kistler (8152B1)	Sensibilidad: 700 V/(m/s) Rango de frecuencia: 50-400 KHz	Uno fijo al husillo; otro fijo en mordaza de sujeción hidráulica
1	Dinamómetro de 3 componentes de fuerza Kistler (9257B)	Rango de fuerza: -7.5 pC/N en ejes x, y, -3.5 pC/N en eje z Frecuencia natural: 3.5 KHz	Fijo en la mordaza de sujeción hidráulica
3	Acelerómetros piezotrónicos Brüel y Kjaer (4370 y 4371)	Sensibilidad de carga: 98 ± 2 pC/g Frecuencia de resonancia: 16 KHz (4370), 42 KHz (4371)	Todos fijos en el aro del husillo

Tabla 3.3. Niveles factoriales para los parámetros de corte en la experimentación.

Niveles	fz (mm/rev)	D_{tool} (mm)	ae (mm)	HB (HBN)	$Curv$ (mm ⁻¹)
Nivel 1	0.025	8	1	71	-0.05
Nivel 2	0.05	10	2	93	-0.025
Nivel 3	0.075	12	3	110	0
Nivel 4	0.1	16	4	136	0.025
Nivel 5	0.130	20	5	157	0.05

En adición a los parámetros de corte, se monitorearon también las señales provenientes del sistema de adquisición de datos durante cada experimento. Estas señales fueron procesadas mediante un método de caracterización llamado *Mel Frequency Cepstrum Coefficients*. El resultado de este proceso fue la obtención de siete coeficientes por cada señal monitoreada.

Las señales consideradas en este proceso fueron:

- Aceleración en la dirección X en la pieza de trabajo.
- Aceleración en la dirección Y en la pieza de trabajo.
- Fuerza de corte en la dirección X .
- Fuerza de corte en la dirección Y .
- Emisión acústica del husillo.
- Emisión acústica en la pieza de trabajo.




Figura 3.4. Medición de Ra en material de trabajo para geometría cóncava.

Para cada experimento se determinaron entonces, los 5 parámetros de corte, las 7 variables de proceso y la Ra resultante.

Para medir el valor de Ra en la pieza de trabajo, Figura 3.4, se procedió de la siguiente manera:

1. Se define el área para medir la Ra .
2. Se definen dos longitudes de evaluación para realizar las mediciones. Para cada longitud, se realizan cinco mediciones, para un total de diez valores obtenidos.
3. Las mediciones se realizan en dos áreas específicas de la superficie de maquinado.
4. Con los diez valores de cada sección se calcula el valor aritmético medio (Ra).

La Figura 3.5 presenta un ejemplo de una medición en una superficie maquinada. Los resultados de la medición se imprimen y se guardan en un archivo de computadora.

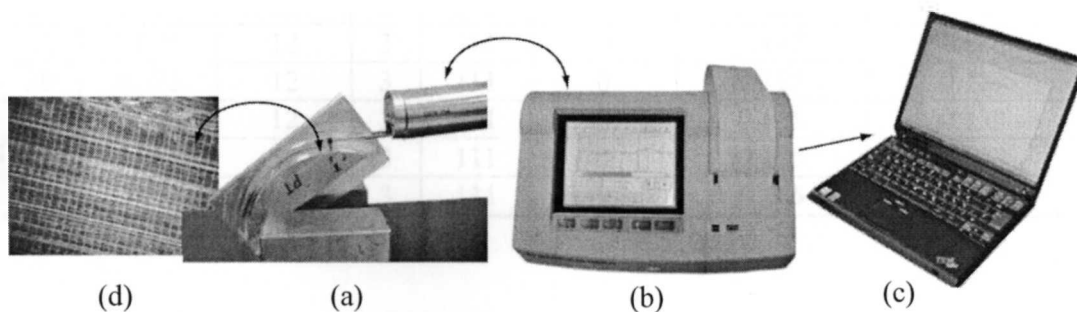


Figura 3.5: Evaluación de la rugosidad superficial. (a) Medición con la punta del Surfcom 130A; (b) Registro e impresión de la información; (c) Almacenamiento de la información; (d) Fotografía de la superficie maquinada.

Tabla 3.4. Experimentos definidos para la condición de herramienta nueva de corte, con los valores de Ra obtenidos en las dos secciones de cada probeta.

Exp	fz	D_{tool}	ae	HB	$Curv$	Ra sección 1	Ra sección 2
1	0.05	10	2	93	0.025	0.115	0.147
2	0.1	10	2	93	-0.025	0.448	0.525
3	0.05	16	2	93	-0.025	0.126	0.104
4	0.1	16	2	93	0.025	0.190	0.230
5	0.05	10	4	94	-0.025	0.191	0.179
6	0.1	10	4	94	0.025	0.524	0.464
7	0.05	16	4	94	0.025	0.118	0.125
8	0.1	16	4	94	-0.025	0.224	0.155
9	0.05	10	2	136	-0.025	0.111	0.117
10	0.1	10	2	138	0.025	0.312	0.299
11	0.05	16	2	138	0.025	0.125	0.126
12	0.1	16	2	136	-0.025	0.160	0.140
13	0.05	10	4	134	0.025	0.145	0.165
14	0.1	10	4	135	-0.025	0.351	0.309
15	0.05	16	4	135	-0.025	0.094	0.077
16	0.1	16	4	134	0.025	0.149	0.154
17	0.025	12	3	111	0	0.097	0.088
18	0.13	12	3	111	0	0.320	0.365
19	0.075	8	3	110	0	0.414	0.526
20	0.075	20	3	110	0	0.163	0.148
21	0.075	12	1	111	0	0.156	0.129
22	0.075	12	5	111	0	0.142	0.156
23	0.075	12	3	70	0	0.172	0.195
24	0.075	12	3	154	0	0.282	0.404
25	0.075	12	3	110	-0.05	0.247	0.157
26	0.075	12	3	111	0.05	0.138	0.172
27	0.075	12	3	111	0	0.125	0.128
28	0.075	12	3	111	0	0.145	0.133
29	0.075	12	3	111	0	0.125	0.128
30	0.075	12	3	111	0	0.145	0.133
31	0.075	12	3	111	0	0.125	0.128
32	0.075	12	3	111	0	0.145	0.133

CAPÍTULO 4

MODELOS DE ANN

La formación de rugosidad superficial es un proceso complejo. Muchos factores incontrolables influyen en este mecanismo, haciendo difícil diseñar el proceso por medio de métodos matemáticos. Las Redes Neuronales, en cambio, han mostrado en varias investigaciones su habilidad de aprender y simular procesos de maquinado, y efectivamente predecir la formación de *Ra* con gran exactitud.

4.1. Definición de una Red Neuronal

Una Red Neuronal está compuesta de un grupo de unidades llamadas neuronas. Una neurona es un procesador, que toma una o más entradas y produce una salida. Tiene las siguientes características:

- Entradas, definidas por x_j , que a su vez son salidas de otras unidades.
- Pesos asociados con las entradas, donde w_{ij} es el peso de la conexión que sale del elemento j y entra al elemento i .
- Una entrada a la red net_i que se define como la suma ponderada de los pesos en sus entradas:

$$net_i = \sum_j w_{ij}x_j$$

- La activación a_i , que es una función de la activación pasada y de la entrada net_i :

$$a_i(t + 1) = F_i[a_i(t), net_i]$$

- La salida, que es una función de la activación:

$$x_i = f_i(a_i)$$

Mientras una sola neurona tiene un uso muy limitado, un número de neuronas conectadas puede ser entrenado para desarrollar ciertas actividades. Los datos se alimentan a la red mediante una capa de entrada, y se procesan dentro de una o más capas intermedias u ocultas, y finalmente se obtiene un resultado a través de la capa de salida.

Para construir una ANN se requieren varios parámetros que deben ser ajustados para realizar determinada tarea. Esto implica definir el número de capas en la ANN, número de

neuronas de entrada/salida, algoritmos de entrenamiento, y funciones de transferencia entre capas. Se detallará el proceso seguido para obtener los modelos óptimos con el mejor desempeño posible en cada uno de los casos, y los resultados preliminares de cada caso.

4.2. Consideraciones generales

4.2.1. Determinación del Número de Neuronas en Capa Oculta

Una de las características más importantes de un ANN es el número de neuronas en la capa intermedia u oculta. Si el número es deficiente, la red será incapaz de modelar datos complejos, y si el número de neuronas es considerable, la red se sobre-entrenará. Para el caso de sobre-entrenamiento el resultado será que el modelo se ajustará muy bien a los datos de entrenamiento, pero generalizará pobremente con nuevos datos. En publicaciones anteriores se ha dado poca importancia al número de neuronas en la capa oculta, considerando un número arbitrario sin base ni justificación. En [Zhang et al, 1998], se presenta una recomendación para seleccionar el número de neuronas en la capa oculta. El autor establece que el número óptimo de neuronas en la capa oculta para un ANN podría ser igual a $n/2$, $1n$, $2n$, o $2n + 1$, donde n es el número de neuronas de entrada. El autor menciona también que estos números a su vez se obtuvieron de investigaciones en las que estas estructuras produjeron buen desempeño, por lo que la determinación de éstos fue heurística. Es importante definir que opción permite generar el modelo de ANN con mejor desempeño.

4.2.2. Algoritmos de Entrenamiento

La mayoría de los algoritmos de entrenamiento se pueden ver como aplicaciones de teoría de la optimización y estimación estadística. Dos algoritmos de entrenamiento se probaron con los modelos Pre-Proceso, la Retro Propagación por Descenso de Gradiente con Razón de Aprendizaje Adaptivo y la Retro Propagación Resiliente. Se decidió utilizar el Descenso por Gradiente ya que este algoritmo es uno de los más comunes, utilizado en varias de las publicaciones que sirvieron de base a esta investigación. La Retro Propagación Resiliente se escogió porque presenta la ventaja de ser uno de los algoritmos más rápidos, y es relativamente actual, desarrollado a principios de los años 90s.

El Descenso por Gradiente es un algoritmo de entrenamiento estándar; su funcionamiento consta de los siguientes pasos:

- Se calcula la salida de la red a partir de los valores iniciales.
- La salida de la red se compara con la salida correcta y se calcula el error.
- Se calculan las derivadas parciales del error con respecto a los pesos.

- Se ajustan los pesos en cada neurona para reducir el error.
- Se repite el proceso hasta llegar a un desempeño deseado.

Las redes de múltiples capas típicamente utilizan funciones de transferencia sigmoideas en las capas ocultas. Estas funciones comprimen un rango infinito de entrada en un rango finito de salida. Esto causa un problema cuando se usa un descenso rápido para entrenar una red, porque el gradiente puede tener una magnitud muy pequeña; y por lo tanto hacer cambios pequeños en pesos y pesos de polarización. La Retro Propagación Resiliente elimina estos efectos, y es uno de los mecanismos de actualización de pesos más rápido.

4.2.3. Normalización de los Datos

Un pre-procesamiento de los datos de entrada y salida son necesarios, principalmente para distribuir los datos uniformemente y escalarlos a un rango aceptable para la red neuronal. Sin la normalización de datos, una ANN no podrá producir resultados con exactitud.

Dos tipos de normalización se utilizaron para entrenar y evaluar datos en la ANN. Uno de ellos es la normalización de los datos con media $\mu = 0$ y desviación estándar $\sigma = 1$. Esta normalización (NORM A) se define como,

$$z = \frac{x - \mu}{\sigma}$$

Donde x es el dato a ser normalizado, μ es la media de la población, y σ es la desviación estándar de la población. Es necesario emplear este tipo de normalización para evadir inestabilidad numérica. Como segundo paso, se utilizó una normalización exponencial (NORM B). La ecuación siguiente describe este tipo de normalización:

$$z = \left\{ \frac{[1 - e^{-x}]}{[1 + e^{-x}]} \right\}$$

Donde x es el dato a normalizar. Este tipo de transformación no lineal previene a la mayoría de los valores de comprimirse en esencialmente los mismos valores, y también comprime los valores más grandes. La Figura 4.1 grafica los valores de Ra para ciertos experimentos, y en la cual puede observarse que la NORM A permite diferenciar los rangos de Ra para evitar inestabilidad numérica. Por otro lado, la NORMA B evita dispersiones mayores en los rangos de los valores de Ra .

4.2.4. Funciones de Activación

Las ANN de múltiples capas usualmente utilizan funciones de activación, las cuales introducen una no linealidad al proceso. Esto es necesario para comprimir un rango de datos que puede ser muy grande, a uno manejable por la ANN. Las funciones más comunes

son la función logarítmica-sigmoidal, que genera salidas entre 0 y 1 mientras que la entrada net va desde el infinito negativo al positivo infinito:

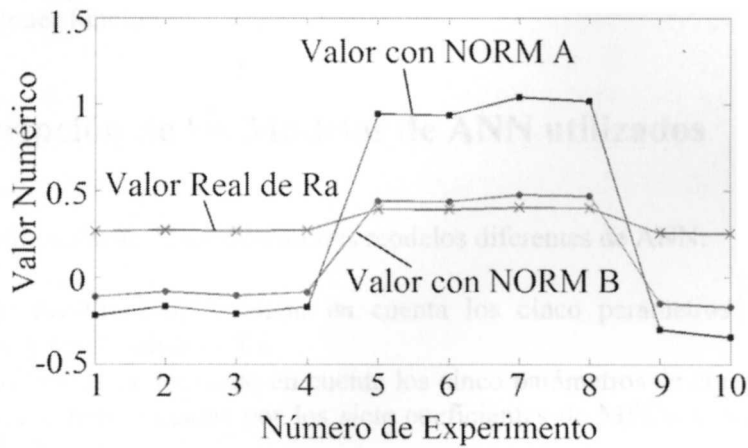


Figura 4.1. Valores de Ra en experimentos, antes y después de normalizarse con los dos métodos.

$$f(net) = \frac{1}{1 + e^{-net}}$$

De manera alterna, las redes neuronales pueden usar la función tangencial-hiperbólica, que genera salidas entre -1 y 1:

$$f(net) = \tanh(net)$$

Estas funciones se utilizan generalmente entre la capa de entrada y la capa oculta, o entre capas ocultas en caso de existir más de una. Ambas funciones se pueden observar en la Figura 4.2.




Figura 4.2. Funciones de transferencia típicas en una ANN.

Adicionalmente, se puede utilizar también una función Lineal. Esta función se utiliza cuando los valores de los datos no están restringidos a algún límite, y consiste en presentar los datos sin manipulación alguna, de manera que puede decirse que la función Lineal equivale a no tener función.

4.3 Descripción de los Modelos de ANN utilizados

Para esta investigación se desarrollaron tres modelos diferentes de ANN:

- Modelo Pre-Proceso, tomando en cuenta los cinco parámetros de corte como entrada, y como salida la *Ra*.
- Modelo En-Línea, tomando en cuenta los cinco parámetros de corte y las variables de proceso representadas por los siete coeficientes de MFCC y como resultado el valor de *Ra*.
- Modelo de detección de la condición de desgaste en la herramienta CTWC, tomando en cuenta los cinco parámetros de corte más siete coeficientes relacionados con MFCC de emisión acústica, y como salida la condición de la herramienta de corte.

4.3.1. Modelo Pre-Proceso

Basados en el supuesto del número óptimo de neuronas en la capa oculta, las estructuras probadas para el primer caso de predicción de *Ra* en Pre-Proceso fueron 5x2x1, 5x5x1, 5x10x1 y 5x11x1. En la Figura 4.3 se observa un modelo general de ANN utilizado para el caso Pre-Proceso.

El primer paso para encontrar la mejor estructura Pre-Proceso de ANN con los parámetros propuestos, fue probar cuatro diferentes modelos. La evaluación de estos modelos se hizo con las siguientes consideraciones:

- Se utilizaron datos solamente para la condición de herramienta Nueva.
- El propósito de estas evaluaciones es determinar el número de neuronas en la capa oculta que produce mejor desempeño para los algoritmos de Descenso por Gradiente (GDA) y Retro Propagación Resiliente (RPROP).
- Las funciones de transferencia utilizadas entre la capa de entrada y la capa oculta son la Logarítmica Sigmoidal y la Tangencial Sigmoidal. Una función Lineal se utilizó entre la capa oculta y de salida.
- Se utilizaron 110 pares de datos (entrada/salida) para entrenar y evaluar los modelos. 70% de los datos se usaron en la etapa de entrenamiento y el resto en evaluar el modelo. Los datos fueron ordenados al azar en cada corrida, y cada estructura se evaluó 10 veces.

- Los datos fueron normalizados con media 0 y desviación estándar de 1 (NORM A).
- Como indicadores de desempeño se escogieron el Error Cuadrático Medio (MSE) que cuantifica la diferencia entre la Ra predicha y la Ra real, y un Factor de Correlación (CF) que indica el nivel de relación estadística entre los valores reales y estimados. Estos indicadores, entre otros, han sido extensamente utilizados en investigaciones similares para evaluar el desempeño de las ANNs.

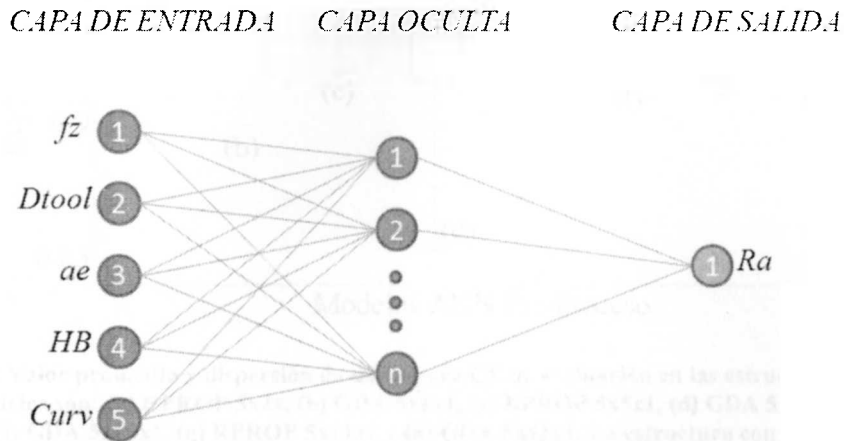


Figura 4.3. Modelo general de ANN para el caso Pre-Proceso. La estructura utiliza los cinco parámetros de corte como entradas, y n número de neuronas de capa oculta (2, 5, 10 y 11). La salida es el valor predictivo de Ra .

Los valores de las corridas se muestran en las Tabla A.1, A.2, A.3 y A.4 del Apéndice A. La Figura 4.4 muestra los valores promedio del CF de evaluación de las 8 estructuras probadas, así como la dispersión mayor y menor lograda con los datos. En la figura se observa que las estructuras con menor número de neuronas (2 y 5) en la capa oculta, presentan mayor dispersión en el valor del CF, mientras que las estructuras con mayor número de neuronas (10, 11) en la capa oculta presentan mejor desempeño y su dispersión es menor al 2%. La estructura con peor desempeño fue 5x2x1, por lo que se decidió eliminarla de subsecuentes corridas y no considerarla posteriormente. Los indicadores de desempeño muestran que la mejor estructura del conjunto es 5x10x1 con Retro Propagación Resiliente. Esta estructura tiene un MSE promedio de 0.0054 y 0.0137 para entrenamiento y evaluación respectivamente.

Consecuentemente, se extendió la investigación sobre las estructuras que presentaron mejor desempeño (5x5x1, 5x10x1 y 5x11x1). Un segundo conjunto de corridas se realizó considerando los siguientes aspectos:

- Se consideró la condición de herramienta Nueva.
- Se probaron diferentes funciones de transferencia entre la capa de entrada y oculta (tan-sig, log-sig) y entre la capa oculta y de salida (lineal).
- Se utilizaron dos tipos de normalización, NORM A y NORM B.

- Para cada configuración los datos se ordenaron al azar y se realizaron 10 corridas diferentes. Al tener varias pruebas con los datos de entrenamiento al azar, se abarca un mayor espectro estadístico que proporciona validez a los resultados.




Figura 4.4 Valor promedio y dispersión de datos para CF de evaluación en las estructuras Pre-Proceso. Los modelos son: (a) RPROP 5x2x, (b) GDA 5x2x1, (c) RPROP 5x5x1, (d) GDA 5x5x1, (e) RPROP 5x10x1, (f) GDA 5x10x1, (g) RPROP 5x11x1 y (h) GDA 5x11x1. La estructura con mejor desempeño fue (e), con un CF de evaluación de 0.9585.

En total, se probaron 32 estructuras diferentes. Como resultado se obtuvo que la estructura 5x10x1 utilizando Retro Propagación Resiliente presentó un mejor desempeño, con funciones de transferencia Logarítmica Sigmoidal entre la capa de entrada y la oculta, y función Lineal entre la capa intermedia y la de salida. Esta configuración se normalizó con el método B. Los promedios de los indicadores de desempeño para esta configuración fueron 0.005 para el MSE de entrenamiento, 0.01 para evaluación, 0.984 para el CF de entrenamiento, y 0.957 para el CF de evaluación. La Figura 4.5 presenta el valor promedio y la dispersión de datos del CF de evaluación de las configuraciones que presentaron mejor desempeño para las arquitecturas 5x5x1, 5x10x1 y 5x11x1. En las Tablas A.5-A.16, que se encuentran en el Apéndice A de esta investigación, se pueden observar los resultados para las estructuras 5x5x1, 5x10x1 y 5x11x1, respectivamente. Las Figuras 4.6 y 4.7 muestran los resultados de una corrida para la estructura RPROP 5x10x1 en entrenamiento y en evaluación, respectivamente.

Una observación importante es la influencia de los tipos de normalización con las funciones de transferencia. Como se observó en la Figura 4.1, la normalización A expande los valores, mientras que la normalización B comprime estos mismos valores normalizados, de manera que se tiene un rango mayor para los valores de normalización A, que los de B. Esto influye directamente en el momento de utilizar las funciones de activación Logarítmica Sigmoidal y Tangencial Hiperbólica. Estas funciones tienen rangos de 0 a 0.5 y de -1 a +1, respectivamente, como se ve en la Figura 4.2, por lo que se puede explicar que estructuras con normalización A se ajusten mejor a una función Tangencial Hiperbólica, y una estructura con normalización B se ajuste mejor a una función Logarítmica. De acuerdo

a los resultados obtenidos, se puede concluir que la normalización B con función Logarítmica presenta en general mejores resultados que la normalización A. La normalización B tiene la ventaja sobre la normalización A, en que comprime los valores de datos más grandes (produciendo datos en un rango menor que la normalización A, pero aún conserva una diferenciación representativa entre los datos para facilitar el funcionamiento de la ANN. En todas las estructuras se utiliza una función Lineal entre la capa oculta y la capa de salida. Esta función de activación equivale a no tener función de activación, y se utiliza cuando no se tienen límites en los valores de salida, como en el caso de esta investigación, ya que el valor de Ra no está restringido a algún rango.

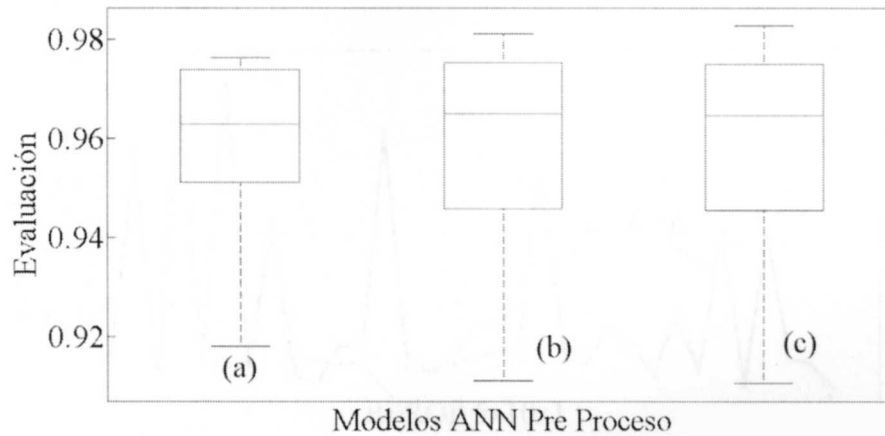


Figura 4.5. Valor promedio y dispersión de datos para CF de evaluación en las estructuras Pre-Proceso con RPROP. Las estructuras son: (a) 5x5x1, (b) 5x10x1 y (c) 5x11x1. La estructura con mejor desempeño fue (b) con un CF de evaluación de 0.9585.

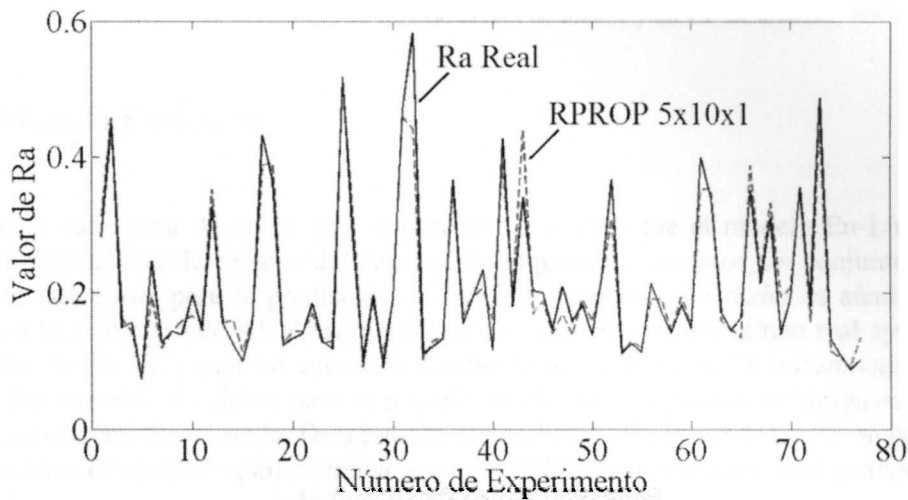


Figura 4.6. Fase de entrenamiento para la ANN utilizando RPROP y una estructura 5x10x1. Esta corrida en particular tuvo un MSE de entrenamiento de 0.0071 y un CF de 0.9764.

Después de realizar estos conjuntos de pruebas, se determinó la estructura óptima para la predicción de Ra Pre-Proceso, siendo ésta la que mejor desempeño presentó con anterioridad (5x10x1, Retro Propagación Resiliente, con funciones de transferencia Logarítmica y Lineal, y normalización B). El siguiente paso a realizar fue la inclusión de los estados de desgaste de herramienta restantes (Semi-Nueva, Semi-Desgastada y Desgastada) para obtener los modelos de ANN. También se tuvo que validar la predicción de Ra con parámetros nuevos, fuera de los indicados en la Tabla 3.4 del Capítulo 3. Esto es para determinar la robustez del sistema predictivo ante valores no considerados en el entrenamiento. Estas nuevas pruebas y resultados se encuentran en el Capítulo 6 de esta investigación.

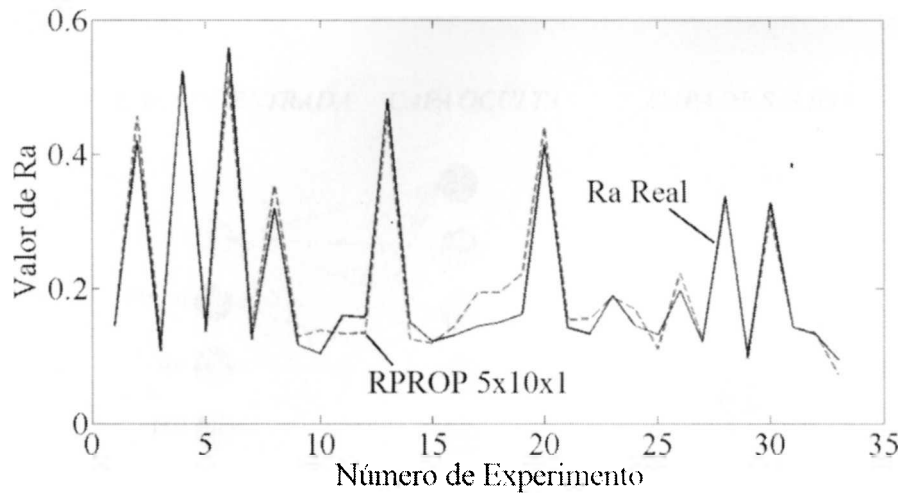


Figura 4.7. Fase de evaluación para la ANN utilizando RPROP y una estructura 5x10x1. Esta corrida en particular tuvo un MSE de evaluación de 0.0077 y un CF de 0.9811.

4.3.2. Modelo En-Línea

La segunda estructura de ANN que se procedió a diseñar fue el modelo En-Línea. Esto sugiere la utilización de señales del sistema de adquisición de datos, en conjunto con los parámetros de corte, para la predicción de Ra en tiempo real. La razón de añadir nuevas entradas a la estructura de ANN, es que las señales del proceso en tiempo real ayudan a la predicción de Ra sin tomar en cuenta la condición de desgaste en la herramienta. Con el modelo Pre-Proceso los datos para el modelo se dividen en estados de desgaste (Nueva, Semi-Nueva, Semi-Desgastada, Desgastada), sin embargo, En-Línea se toman en cuenta los cuatro estados en conjunto para entrenar una sola ANN. La nueva estructura general para el proceso En-Línea se observa en la Figura 4.8.

Para obtener la estructura con mayor desempeño en el modo En-Línea, se realizaron pruebas para determinar el grado de error de las ANN propuestas. Las consideraciones tomadas en este conjunto de pruebas son las siguientes:

- Se tomaron 880 pares de datos con los que se entrenó y evaluó cada estructura de ANN, 220 de cada CTWC. 70% de los datos se utilizaron para la fase de entrenamiento y el restante 30% para la fase de evaluación.
- Los datos se ordenaron al azar para cada corrida, y se realizaron 10 corridas por estructura probada.
- Se probaron cuatro señales de proceso distintas provenientes del sistema de adquisición de datos: Aceleración en X , aceleración en Y , fuerza en X y fuerza en Y durante el corte.

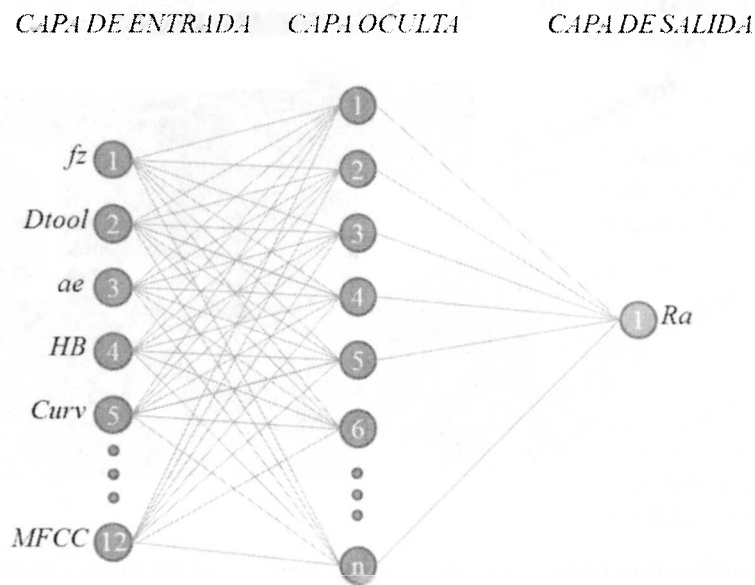


Figura 4.8. Estructura general para el modelo de predicción En-Línea. Las variables del proceso se caracterizan por medio de MFCC y se añaden a los parámetros de corte considerados anteriormente, para totalizar 12 entradas. Se probaron diferentes números de neuronas en la capa oculta, comenzando con 6. Este número se representa con la letra n . El valor predictivo de Ra es la salida de la ANN

Las aceleraciones corresponden a las vibraciones obtenidas durante el maquinado de una pieza, medidas en la dirección X y Y . Las fuerzas consideradas se midieron utilizando una plataforma dinamométrica. La Figura 4.9 presenta la ubicación de los sensores que se utilizaron para medir estas señales, en el centro de maquinado.

- Cada una de estas señales pasó por un proceso conocido como MFCC para caracterizarla con 7 valores [Vallejo et al., 2005]. Estos valores sumados a los parámetros de corte dan un total de 12 entradas al modelo de ANN.

- Las funciones de transferencia utilizadas fueron Log-Sig entre la capa de entrada y la capa oculta, y Lineal, entre la capa oculta y la capa de salida. La normalización de todos los datos fue del tipo NORM B.
- Utilizando el criterio de número óptimo de neuronas en la capa oculta, se probaron los valores de 6, 12, 24 y 25 neuronas.

Los resultados del conjunto de pruebas para determinar la mejor estructura de predicción de Ra en modo En-Línea se encuentran en las Tablas A.17, A.18, A.19 y A.20 del Apéndice A de la investigación, para las señales de Aceleración en X , Aceleración en Y , Fuerza en X y Fuerza en Y , respectivamente.




Figura 4.9. Distribución de los sensores de medición de señales del proceso en el centro de maquinado.

En base a los indicadores de desempeño, se determinó que la mejor estructura fue 12x12x1 y utilizó las señales provenientes de la componente X de la fuerza. Se tomó en cuenta la fase de evaluación (MSE y CF) para concluir cual fue la mejor propuesta de ANN. Los promedios de los indicadores de desempeño para esta ANN fueron 0.013 de MSE en entrenamiento, 0.029 para evaluación, 0.953 como CF en fase de entrenamiento y 0.894 para fase de evaluación. La Figura 4.10 muestra el valor promedio y la dispersión de datos para la estructura de mejor desempeño en cada una de las señales del proceso.

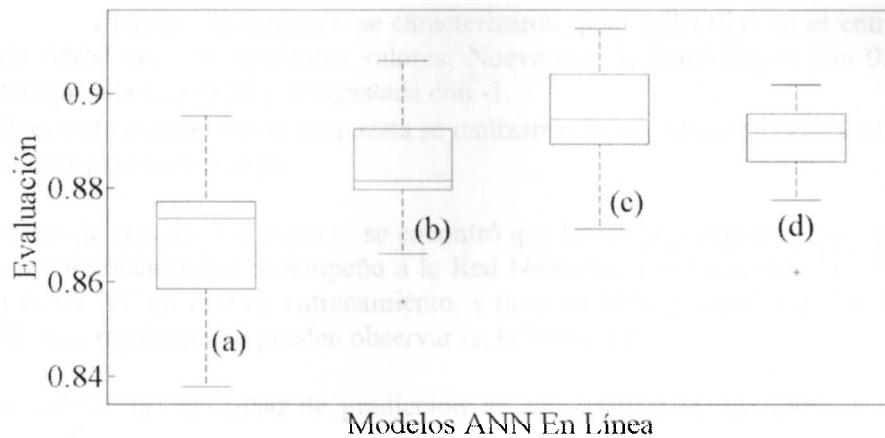


Figura 4.10. Valor promedio y dispersión de datos para CF de evaluación en estructuras ANN En-Línea. Las estructuras son: (a) 12x12x1 Acel. X, (b) 12x12x1 Acel. Y, (c) 12x12x1 Fza. X y (d) 12x12x1 Fza. Y. La estructura (c) tuvo mejor desempeño, con CF de evaluación de 0.894.

Nuevas pruebas se realizaron después de haber determinado la estructura óptima para predicción de *Ra* En-Línea. Estas pruebas subsecuentes validan la capacidad predictiva del ANN, utilizando nuevos valores de parámetros de corte diferentes de los utilizados para el entrenamiento de la Red Neuronal. Estos resultados se encuentran en el Capítulo 6 de esta investigación.

4.3.3. Modelo de Detección de CTWC

La detección de la condición de desgaste se refiere a la identificación de los cuatro estados propuestos (Nueva, Semi-Nueva, Semi-Desgasta y Desgastada) en el proceso En-Línea. Para esto se utilizan más variables del proceso, caracterizadas mediante MFCC.

El conjunto de pruebas de detección de CTWC se hizo para observar el desempeño entre las señales acústicas de la pieza y las señales acústicas del husillo como variables de proceso. Las siguientes son las consideraciones que se tomaron para ejecutar las pruebas:

- Se utilizó una estructura 12x12x1 con RPROP con variables del proceso (MFCC), siendo esta la que presentó mejor desempeño en condiciones En-Línea, en la sección 4.3.2 de este Capítulo, dentro de las opciones $n/2$ (6), n (12), $2n$ (24) y $2n+1$ (25) de número de neuronas en capa oculta. Como entradas se usaron los cinco parámetros de corte, más los siete valores de las señales acústicas. La estructura ANN utilizada se puede observar en la Figura 4.11.
- Se utilizaron 110 pares de datos (entrada/salida) de cada una de las cuatro condiciones de desgaste, totalizando 440 datos para entrenamiento y evaluación.

- Las condiciones de desgaste se caracterizaron, para utilizarlas en el entrenamiento de ANN, con los siguientes valores: Nueva con 1, Semi-Nueva con 0.33, Semi-Desgastada con -0.33 y Desgastada con -1.
- Para cada configuración propuesta se realizaron 10 corridas, seleccionando los datos al azar para cada corrida.

Después de ejecutar las pruebas, se encontró que las señales acústicas provenientes del husillo proporcionan mejor desempeño a la Red Neuronal. Prácticamente la ANN detectó sin error la CTWC en fase de entrenamiento, y tuvo un MSE promedio de las 10 corridas de 0.0182. Los resultados se pueden observar en la Tabla 4.1.

Para validar la capacidad de predicción de esta estructura de ANN, se efectuaron nuevas pruebas con datos de parámetros de corte y de señales acústicas diferentes a los utilizados para el entrenamiento de las Redes Neuronales. Estos nuevos resultados se comentan en el Capítulo 6 de esta investigación.

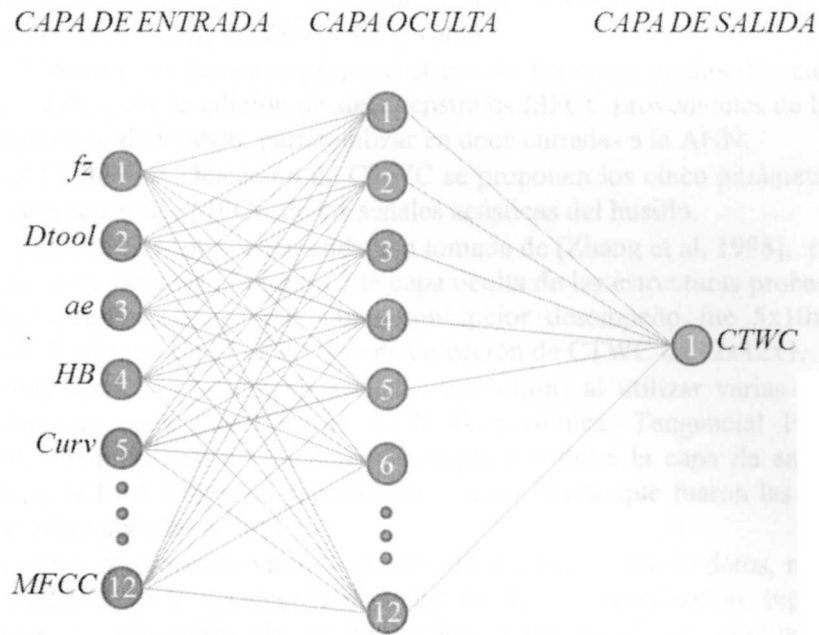


Figura 4.11. Propuesta de estructura para detección de condición de desgaste en herramienta de corte. Se utilizan los cinco parámetros de maquinado más siete valores que caracterizan las señales acústicas. Como salida se tiene una de las cuatro CTWC.

Tabla 4.1. Resultados en la detección de CTWC utilizando señales acústicas de la pieza de trabajo y del husillo. Se puede observar que para las señales del husillo no existe error en entrenamiento, y tuvo un error de 0.0182 en fase de evaluación.

	INDIC.	1	2	3	4	5	6	7	8	9	10	PROM	DSV ST
HUS	MSE ENT	0	0	0	0	0	0	0	0	0	0	0	0
	MSE EVAL	0.010	0.006	0.030	0.016	0.013	0.013	0.053	0.010	0.016	0.010	0.018	0.013
PZA	MSE ENT	0	0.001	0.001	0	0.001	0.020	0.027	0.011	0.018	0.015	0.009	0.009
	MSE EVAL	0.030	0.033	0.060	0.047	0.077	0.226	0.259	0.239	0.356	0.212	0.154	0.111

Las siguientes son las contribuciones logradas en este capítulo:

- Este trabajo propone tres nuevos modelos de ANN para predecir la Ra y el CTWC en un proceso de fresado HSM: Modelo Pre-Proceso, Modelo En-Línea y Detección de CTWC.
- Para el Modelo Pre-Proceso se propone el uso de cinco parámetros de corte como entrada de la ANN: f_z , ae , D_{tool} , HB y $Curv$.
- Para el Modelo En-Línea se propone el uso de los cinco parámetros anteriormente mencionados, con la adición de siete cepstrales MFCC provenientes de la Fuerza en X del proceso de fresado, para totalizar en doce entradas a la ANN.
- Para el Modelo de Detección de CTWC se proponen los cinco parámetros de corte más siete cepstrales MFCC de las señales acústicas del husillo.
- Se propone utilizar una recomendación tomada de [Zhang et al, 1998], para obtener el número de neuronas óptimo en la capa oculta de las estructuras probadas. Para el Modelo Pre-Proceso, la estructura con mejor desempeño fue 5x10x1, para el Modelo En-Línea, de 12x12x1 y para Detección de CTWC de 12x12x1.
- Se compararon los desempeños de las estructuras al utilizar varias funciones de transferencia entre capas de la ANN (Logarítmica, Tangencial Hiperbólica y Lineal). Se proponen las funciones Logarítmica entre la capa de entrada y capa oculta, y la Lineal entre la capa oculta y la de salida, que fueron las que tuvieron mejor desempeño en las pruebas.
- Así mismo, se probaron varios métodos de normalización de datos, normalización con media de 0 y desviación estándar de 1, y normalización exponencial. Se propone la utilización de normalización exponencial, en conjunción con la normalización de media 0.
- Se propone utilizar un nuevo algoritmo de entrenamiento en comparación con las investigaciones antecedentes: Retro Propagación Resiliente, con excelentes resultados: Para el Modelo Pre-Proceso, los indicadores de desempeño fueron 0.005 en MSE de entrenamiento, y 0.01 en evaluación, 0.984 en CF de entrenamiento y 0.957 en evaluación. Para el Modelo En-Línea, el desempeño fue de 0.013 en MSE de entrenamiento, 0.029 para evaluación, 0.953 en CF de entrenamiento y 0.894 en evaluación. El Modelo de Detección de CTWC no presentó error en la detección de CTWC en entrenamiento, y tuvo un error de 0.0182 en MSE de evaluación.

CAPÍTULO 5

OPTIMIZACIÓN DE LA RUGOSIDAD SUPERFICIAL

Este capítulo aborda los aspectos teóricos de un Algoritmo Genético. Un AG es un método de optimización extensamente usado en investigaciones que lo utilizan en conjunción con ANNs para determinar aspectos óptimos del maquinado. En esta investigación el AG se utiliza para optimizar los parámetros de corte del fresado en HSM para obtener un valor de Ra deseado. Para lograr esto, se usa junto con el modelo de ANN Pre-Proceso de predicción de Ra , analizado en el Capítulo 4 de esta investigación.

5.1 Concepto de Algoritmo Genético

Un algoritmo genético es un método de búsqueda inteligente, el cual basa su funcionamiento en dinámicas de la evolución, como son la selección natural, sobrevivencia del más apto, y genética. Los AGs explotan eficientemente información pasada para especular sobre nuevos puntos de búsqueda con mejor desempeño.

Los AGs fueron inventados por John Holland en la década de los 60s, siendo desarrollados consecuentemente por él y un equipo de estudiantes y colegas en la Universidad de Michigan en los 60s y 70s [Goldberg, 1989]. El objetivo original de Holland no fue diseñar algoritmos para resolver problemas específicos, sino estudiar formalmente el fenómeno de adaptación como ocurre en la naturaleza y desarrollar formas en que los mecanismos de adaptación pueden importarse en sistemas computacionales. En el libro *Adaptation in Natural and Artificial Systems* de 1975, Holland presenta al AG como una abstracción de la evolución biológica e introduce los conceptos de selección, cruce y mutación. El trabajo de Holland sentó las bases para la elaboración de nuevas variaciones y avances en la teoría de AGs.

Un AG está compuesto de una población de individuos, que en caso de no tener información sobre la función objetivo, pueden ser inicialmente generados al azar. Cada uno de estos individuos posee lo que se conoce como un “cromosoma”, utilizando como analogía su similar en la naturaleza. Un cromosoma de cualquier individuo posee dos características importantes: un genotipo y un fenotipo. El genotipo son cadenas de bits binarios, generalmente, aunque existen variaciones que utilizan caracteres decimales. Los genotipos son las partes que serán manipuladas por el AG, y representan valores de una solución específica para el problema que se intenta resolver. El fenotipo son valores representados por el genotipo, y con estos se evalúa la función a optimizar.

Al comenzar un AG, la población inicial es evaluada. Intrínsecamente, lo que se está analizando son “esquemas” en los individuos. Se entiende por esquema a un patrón de bits,

con propiedades que son su longitud y su orden. En una evaluación de una población de AGs, los individuos que poseen en su cromosoma los esquemas mejor evaluados tienen mayores posibilidades de generar “hijos”, después de un proceso de selección. Este proceso se conoce como Reproducción. Un operador de reproducción puede ser implementado en la forma de un algoritmo de diferentes maneras. La Tabla 5.1 ejemplifica una población de un AG con su evaluación para una función de maximización.

Tabla 5.1. Evaluación de una población para función de maximización de “1s”.

No. Individuo	Genotipo	Evaluación
1	01100001	97
2	10100111	167
3	00010010	18
4	11110111	247
5	10011001	153

Después de la reproducción, la población se enriquece con individuos más aptos de la generación pasada, pero no tiene ningún nuevo individuo. El concepto de Cruce se refiere a la generación de nuevos individuos por la combinación del genotipo de dos diferentes “padres”. Mientras las generaciones pasan, los patrones mejor evaluados prevalecerán y la evaluación promedio de la población se incrementará, hasta que el criterio de terminación de la función objetivo se cumpla. La Figura 5.1 representa la ejecución de un cruce en dos individuos.




Figura 5.1. Cruce entre dos individuos en un AG.

El tercer paso, Mutación, es la alteración ocasional de un valor en una posición del cromosoma, al azar, con una pequeña probabilidad. La necesidad de la mutación es mantener la diversidad en la población. La Figura 5.2 ilustra el flujo del método de un AG para resolver un problema de optimización.

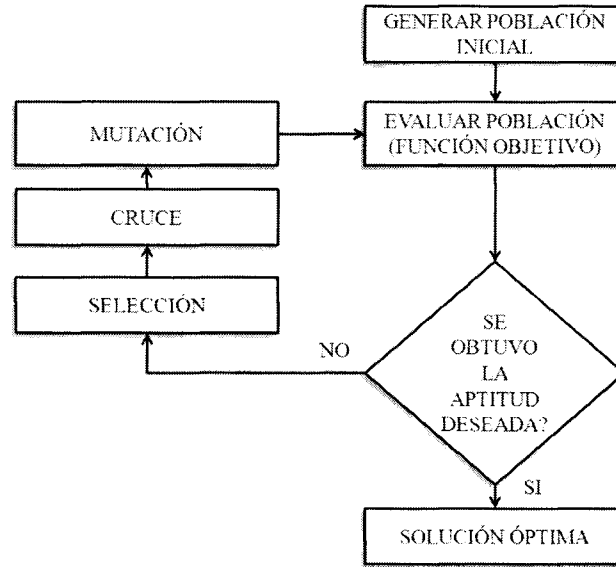


Figura 5.2. Diagrama de flujo para la ejecución de un AG. Primero se genera la población inicial, después se codifica y se evalúa en la función objetivo. Si no se logra la solución óptima, se genera una nueva población “mejorada”, basada en tres operadores: Selección, Cruce y Mutación. El ciclo se repite hasta llegar a un criterio de terminación.

5.2 Optimización de los Parámetros de Maquinado

Para la fase de optimización, un AG se usó en conjunción con la estructura de ANN propuesta para Pre- Proceso. El AG utilizado se programó utilizando las funciones para AGs del software MatLab 2009. La función objetivo utilizada para evaluar a los individuos funciona de la siguiente manera:

- Se recibe como entrada los valores de los parámetros de corte (fz , ae , $Dtool$, HB y $Curv$), y el valor deseado de Ra .
- El programa introduce los parámetros de corte en la Red Neuronal previamente entrenada, y produce un valor predictivo de Ra como salida.
- Se obtiene el error absoluto entre el valor deseado y el valor predictivo de Ra , y este error se convierte en la salida de la función objetivo. Este proceso se describe en la Figura 5.3.

En el proceso de optimización, solo tres de los cinco parámetros de corte se consideraron como variables para el AG: fz , ae y $Dtool$. El resto de los parámetros, $Curv$ y HB , son fijos porque están inherentes a las características de la pieza de trabajo.

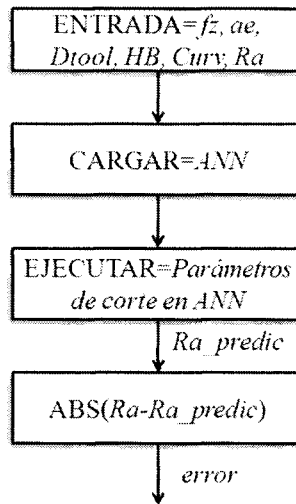


Figura 5.3. Diagrama de flujo representando la función objetivo. Cada individuo de la población se evalúa y el valor regresado indica la proximidad de la Ra predictiva con el valor deseado de Ra .

La secuencia de optimización utilizada en el programa consiste en tres pasos:

- Primero, el AG busca la solución óptima variando el parámetro fz , lo cual sería la solución más práctica en la implementación.
- Si no se encuentra una solución, el AG añade ae como variable, junto con fz , y comienza una nueva búsqueda.
- Si no se obtiene el desempeño deseado, como última instancia se añade $Dtool$ como nueva variable junto con fz y ae . La secuencia se muestra en el diagrama de flujo en la Figura 5.4.

Los parámetros usados para configurar el AG son los siguientes:

Tamaño de Población: 20. Un tamaño grande de población ayuda a procesar los patrones y reduce los cambios de convergencia prematura. En este caso, el AG optimiza tres parámetros como máximo, y uno como mínimo, entonces establecer un tamaño relativamente grande de población produciría un desperdicio en recursos de la computadora y en iteraciones de la función objetivo.

Operador de Cruce: 0.8. Este operador es en gran parte responsable del progreso de la búsqueda. Se refiere a la fracción de la población que generará “hijos”. Es usualmente una fracción entre 0.7 y 0.9.

Función de Mutación: MutationAdaptFeasible. Esta función pertenece a las herramientas del software de AGs de MatLab. Se usa para satisfacer restricciones lineales de manera que el AG sólo genere individuos factibles.

Número de Generaciones: 100. Se refiere al número máximo de nuevas poblaciones que se generarán en el AG.

Función de Selección: Torneo. La selección por torneo da más copias al individuo con mejor desempeño, la mitad de ese número a la media y cero al peor.

Límite de Aptitud: 0.001. El límite de aptitud es el objetivo al que se desea llegar con la optimización. En este caso, se refiere a la diferencia entre los valores de Ra deseados y los valores predictivos.

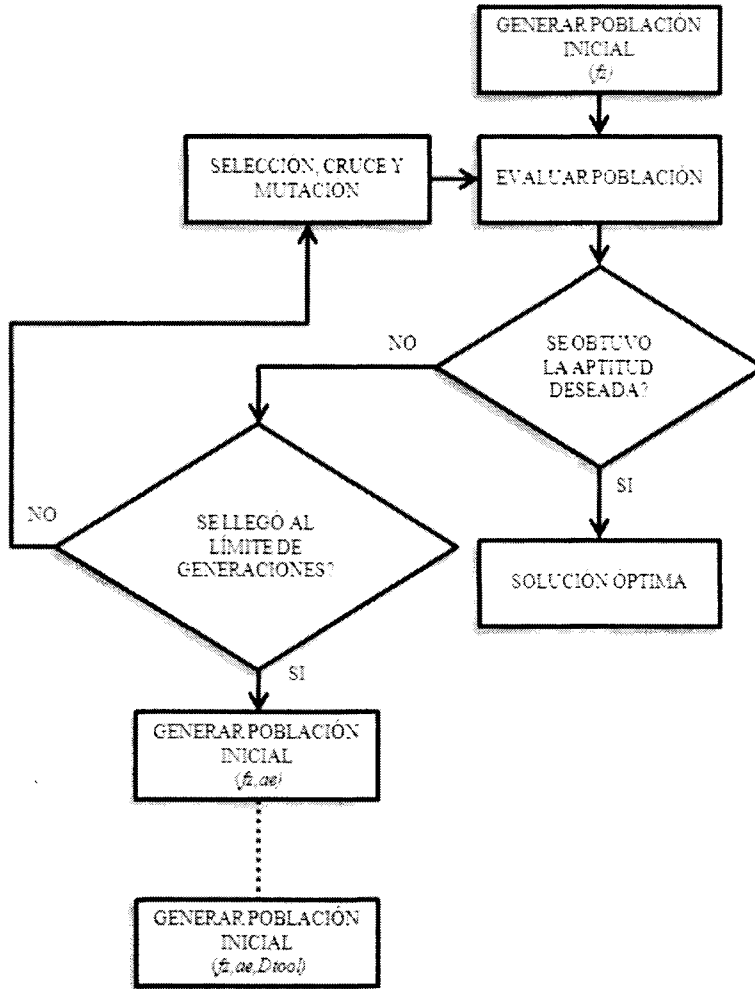


Figura 5.4. Secuencia usada en el programa de optimización con AGs. La primera población considera solamente fz en la optimización. Si no se llega a una solución, se construye una nueva población con fz y ae , y como última instancia se añade $Dtool$.

Para validar la habilidad de optimización del sistema, se escogieron varios casos de los experimentos de maquinado. Los resultados de optimización se discuten en el Capítulo 6 de esta investigación.

CAPÍTULO 6

ANÁLISIS DE RESULTADOS

En esta sección se reportan los resultados subsecuentes para los modelos de ANN en Pre-Proceso, En-Línea y detección de CTWC del Capítulo 4. También se presentan los resultados del sistema de optimización por medio de Algoritmos Genéticos del Capítulo 5.

6.1 Resultados y Validación de Modelo de ANN Pre-Proceso

Después de obtener el modelo con mejor desempeño en el Capítulo 4 (5x10x1 con Retro Propagación Resiliente), se procedió a realizar pruebas con las restantes condiciones de desgaste (Semi-Nueva, Semi-Desgastada y Desgastada). Estas pruebas se realizaron con las siguientes especificaciones:

- Se tomaron en cuenta las cuatro condiciones de desgaste en la herramienta. De cada condición se tomaron 220 experimentos (entrada/salida). 70% de estos se utilizaron en la fase de entrenamiento y 30% en evaluación.
- Se realizaron 10 corridas por estructura, ordenando los datos al azar en cada corrida.
- Además del modelo 5x10x1 con RPROP, también se probaron los modelos 5x5x1 RPROP y 5x10x1 con Descenso por Gradiente. Esto para verificar el comportamiento de otras estructuras con buen desempeño ante otras condiciones de desgaste de herramienta.

Los resultados que se obtuvieron se pueden observar en las Tablas A.21, A.22 A.23 y A.24 de la sección Apéndice A de esta investigación. Los mejores resultados de desempeño para cada una de las condiciones de desgaste se obtuvieron con la estructura RPROP 5x10x1 y se muestran en la Tabla 6.1. Las Figuras 6.1 y 6.2 presentan el valor promedio para cada estructura y la dispersión de datos del CF de evaluación. La fase de evaluación de las corridas de cada CTWC que presentaron mejor desempeño de la estructura RPROP 5x10x1 se muestran en las Figuras 6.3, 6.4, 6.5 y 6.6.

Tabla 6.1. Indicadores de desempeño para la estructura 5x10x1 RPROP en las cuatro condiciones de desgaste.

Indicador	Nueva	Semi-Nueva	Semi-Desgastada	Desgastada
MSE Entrenamiento	0.00658	0.01199	0.01977	0.01146
MSE Evaluación	0.01179	0.01782	0.02731	0.01584
CF Entrenamiento	0.97953	0.96526	0.92612	0.96395
CF Evaluación	0.96295	0.94823	0.90888	0.9504

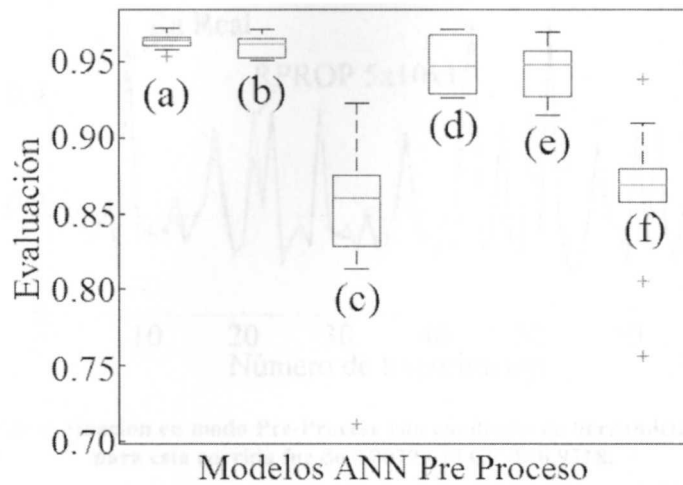


Figura 6.1. Valor promedio y dispersión de datos para CF de evaluación para estructuras en condición Nueva y Semi-Nueva. Las estructuras probadas son: (a)(d) RPROP 5x10x1, (b)(e) RPROP 5x5x1 y (c)(f) GDA 5x10x1. Los valores de CF para estas estructuras en condición Nueva son 0.9629, 0.9604 y 0.8486, en ese orden. Para las estructuras en condición Semi-Nueva, el CF de evaluación es 0.9482, 0.9443 y 0.8618, respectivamente.




Figura 6.2. Valor promedio y dispersión de datos para CF de evaluación para estructuras en condición Semi-Desgastada y Desgastada. Las estructuras probadas son: (a)(d) RPROP 5x10x1, (b)(e) RPROP 5x5x1 y (c)(f) GDA 5x10x1. Los valores de CF para estas estructuras en condición Semi-Desgastada son 0.9088, 0.9084 y 0.8366, respectivamente. Para la condición Desgastada, el CF de evaluación es 0.9504, 0.9497 y 0.8636, en ese orden.

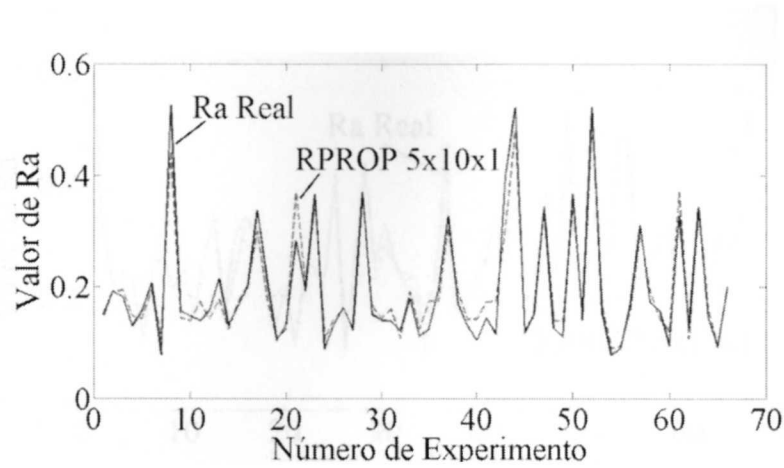


Figura 6.3. Fase de evaluación en modo Pre-Proceso con condición de herramienta Nueva. El MSE para esta corrida fue de 0.0079 y el CF de 0.9718.




Figura 6.4. Fase de evaluación en modo Pre-Proceso con condición de herramienta Semi-Nueva. El MSE para esta corrida fue de 0.0105 y el CF fue de 0.9708.




Figura 6.5. Fase de evaluación en modo Pre-Proceso con CTWC de Semi-Desgastada. El MSE para esta corrida en particular fue de 0.0249 y el CF fue de 0.9465.




Figura 6.6. Fase de evaluación en modo Pre-Proceso con CTWC de Desgastada. El MSE para esta corrida fue de 0.0097 y el CF fue de 0.9716.

Después de obtener estos resultados, se procedió a validar la robustez y habilidad predictiva de la estructura propuesta con nuevos datos de parámetros de corte. Los nuevos valores de los parámetros de maquinado se presentan en la Tabla B.1 del Apéndice B.

La estructura propuesta se comparó con una estructura de una investigación similar [Vallejo et al, 2009]. Esta estructura utiliza los cinco parámetros de corte y además siete variables del proceso de MFCC (12x12x1). Ambas estructuras se entrenaron y evaluaron con los mismos datos. Los resultados de las pruebas de validación y comparación se pueden observar en la Tabla 6.2. Las Figuras 6.7, 6.8, 6.9 y 6.10 presentan los resultados de la fase de evaluación con nuevos datos entre las dos estructuras ANN para las cuatro condiciones de desgaste en la herramienta de corte.

Tabla 6.2. Comparación del MSE de validación entre dos estructuras de ANN.

CTWC	RPROP 5x10x1	ANN 12x12x1 [Vallejo et al, 2009]
Nueva	0.00003379	0.000406
Semi-Nueva	0.0021	0.0264
Semi-Desgastada	0.0067	0.0114
Desgastada	0.0035	0.0105

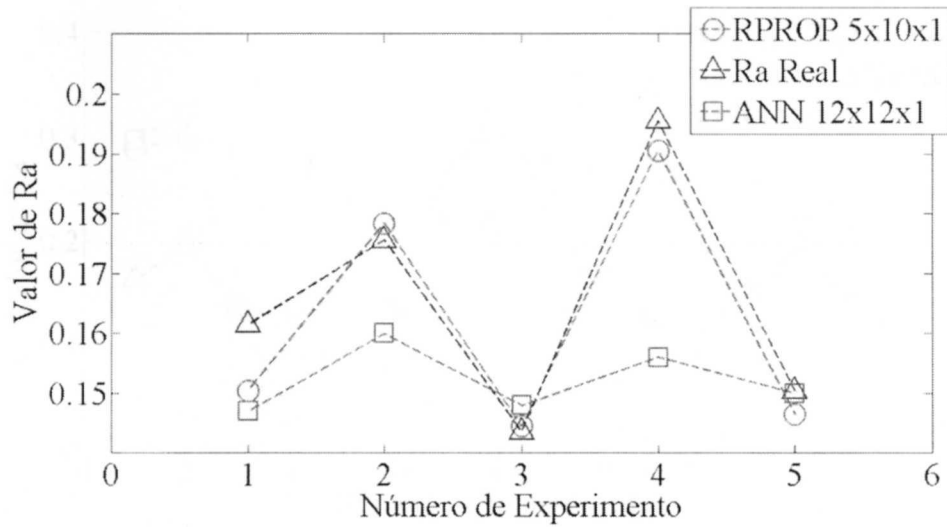


Figura 6.7. Validación de la predicción de Ra para la condición de herramienta Nueva. Dos estructuras se comparan: RPROP con 5x10x1 (esta investigación) y ANN con 12x12x1 [Vallejo et al, 2009]. El MSE de la estructura 5x10x1 es de 0.00003379, y el de la estructura 12x12x1 es de 0.000406. Esto presenta una mejora de 1200% en la nueva estructura 5x10x1 RPROP con respecto a 12x12x1.

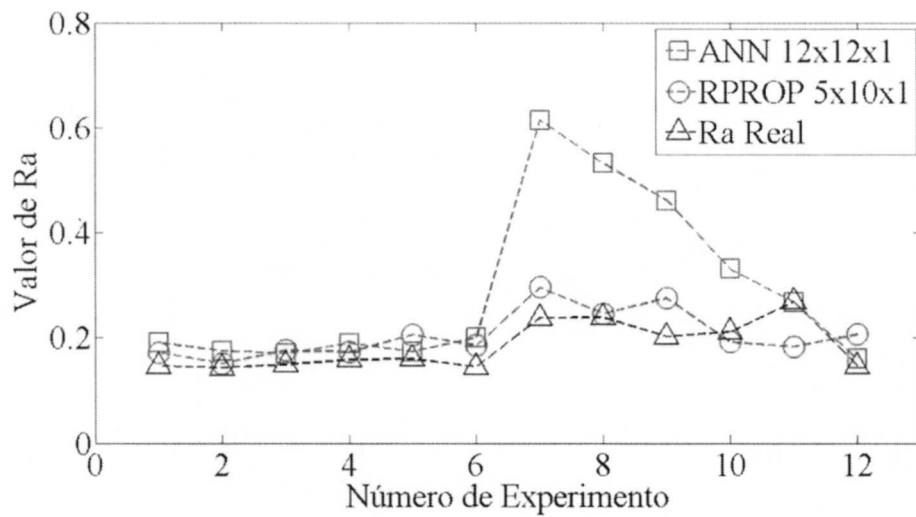


Figura 6.8. Validación de la predicción de Ra para la condición de herramienta Semi-Nueva. Dos estructuras se comparan: RPROP con 5x10x1 (esta investigación) y ANN con 12x12x1 [Vallejo et al, 2009]. El MSE de la estructura 5x10x1 es de 0.0021 y el de la estructura 12x12x1 es de 0.0264. Esto es una mejora de 1250% en el desempeño.




Figura 6.9. Validación de la predicción de Ra para la condición de herramienta Semi-Desgastada. Dos estructuras se comparan: RPROP con 5x10x1 (esta investigación) y ANN con 12x12x1 [Vallejo et al, 2009]. El MSE de la estructura 5x10x1 es de 0.0067 y el de la estructura 12x12x1 es de 0.0114. La mejora en esta condición es de 170%.

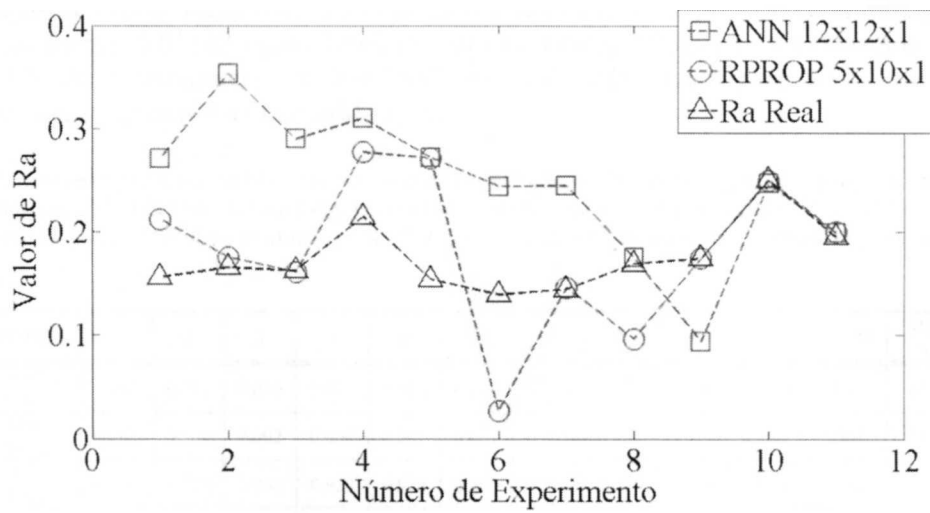


Figura 6.10. Validación de la predicción de Ra para la condición de herramienta Desgastada. Dos estructuras se comparan: RPROP con 5x10x1 (esta investigación) y ANN con 12x12x1 [Vallejo et al, 2009]. El MSE de la estructura 5x10x1 es de 0.0035 y el de la estructura 12x12x1 es de 0.0105. La mejora presentada es de 300%.

6.2 Resultados y Validación de Modelo de ANN En-Línea

Para validar el modelo ANN En-Línea se probó la estructura del Capítulo 4.3.2. Esta estructura es de 12x12x1 con los Cepstrales de la fuerza en la dirección X , Retro Propagación Resiliente, con funciones de activación Logarítmica Sigmoidal entre la capa de entrada y la capa oculta, y Lineal entre la capa oculta y la de salida, con un pre procesamiento de datos con normalización exponencial. Las pruebas de validación se realizaron con las siguientes consideraciones:

- En la fase de entrenamiento se utilizaron 880 pares de datos (entrada/salida) correspondientes a los parámetros de corte y siete variables de MFCC como entradas, y el valor de Ra como salida. Estos datos abarcan las cuatro condiciones de desgaste en la herramienta de corte (Nueva, Semi-Nueva, Semi-Desgastada y Desgastada).
- En la fase de evaluación (validación) se utilizaron 26 pares de datos de experimentos con parámetros nuevos, tomados de la Tabla B.1 del Apéndice B.
- Se realizaron 10 corridas para dar validez al resultado.

Los resultados de muestran que el modelo ANN En-Línea tuvo muy buen desempeño. Estos aparecen en la Tabla 6.4. Los indicadores de desempeño que obtuvo el modelo ANN En-Línea fueron 0.01148 como MSE de entrenamiento, 0.002018 en evaluación, 0.9592 como CF de entrenamiento y 0.963459 en evaluación. La Figura 6.11 muestra los resultados en evaluación de la corrida cinco.

Tabla 6.3. Resultados para validación con nuevos experimentos de modelo ANN En-Línea. El modelo es una estructura 12x12x1 con Retro Propagación Resiliente. Obtuvo un desempeño de 0.0114 en MSE de entrenamiento, 0.0020 en evaluación, 0.9592 como CF de entrenamiento y 0.9634 en evaluación.

INDIC.	1	2	3	4	5	6	7	8	9	10	PROM	DSV ST
MSE ENT	0.010	0.011	0.010	0.012	0.010	0.012	0.010	0.011	.0110	0.012	0.011	0.001
MSE EVAL	0.002	0.001	0.002	0.003	0.001	0.001	0.002	0.002	0.001	0.003	0.002	0.001
CF ENT	0.962	0.957	0.962	0.932	0.984	0.969	0.945	0.963	0.983	0.943	0.963	0.018
CF EVAL	0.962	0.985	0.962	0.932	0.984	0.969	0.945	0.963	0.983	0.943	0.963	0.018

6.3 Resultados y Validación de ANN en Detección de CTWC

Para validar la detección de CTWC se realizaron pruebas con 26 nuevos experimentos, mostrados en la Tabla B.2 del Apéndice B. La estructura ANN utilizada para estas pruebas fue la de la sección 4.3.3. El modelo es 12x12x1, utilizando cinco parámetros de corte y

siete variables MFCC de señales acústicas como entradas, y uno de los cuatro estados de desgaste en la herramienta de corte como salida. Se tomaron en cuenta las siguientes consideraciones para estas pruebas:




Figura 6.11. Validación de la predicción de Ra para proceso En-Línea con experimentos nuevos. Esta estructura 12x12x1 obtuvo un MSE de evaluación de 0.0008 y un CF de evaluación de 0.9847.

- En la fase de entrenamiento se utilizaron 440 pares de datos (entrada/salida) correspondientes a los parámetros de corte y siete variables de MFCC de señales acústicas como entradas, y la CTWC como salida.
- En la fase de evaluación (validación) se utilizaron los 26 pares de datos de experimentos con parámetros nuevos de la Tabla B.1 del Apéndice B.
- Se realizaron 10 corridas para dar validez al resultado.

Los indicadores de desempeño de las pruebas realizadas indican una excelente predicción de la condición de desgaste en la herramienta de corte. El promedio de las diez corridas para MSE de entrenamiento fue de 0.0033, para evaluación de 0.0241, el CF de entrenamiento fue de 0.9912 y el de evaluación de 0.9749. Estos resultados pueden observarse en la Tabla 6.4. La Figura 6.12 muestra el resultado de validación de una corrida del ANN para la detección de CTWC.

Tabla 6.4. Resultados para validación con nuevos experimentos de modelo ANN de CTWC. El modelo es una estructura 12x12x1 con Retro Propagación Resiliente, se utilizó para detección de condición de desgaste en la herramienta de corte. Obtuvo un desempeño de 0.0033 en MSE de entrenamiento, 0.0241 en evaluación, 0.9912 como CF de entrenamiento y 0.9749 en evaluación.

INDIC.	1	2	3	4	5	6	7	8	9	10	PROM	DSV ST
MSE ENT	0.002	0.003	0.002	0.004	0.004	0.002	0.002	0.005	0.005	0.004	0.003	0.001
MSE EVAL	0.034	0.034	0.034	0.017	0.000	0.034	0.034	0.017	0.000	0.034	0.024	0.014
CF ENT	0.995	0.990	0.994	0.989	0.989	0.995	0.995	0.987	0.986	0.988	0.991	0.003
CF EVAL	0.964	0.961	0.964	0.981	1	0.964	0.964	0.982	1	0.964	0.974	0.015




Figura 6.12. Validación de la detección de CTWC con experimentos nuevos. Esta estructura 12x12x1 obtuvo un MSE de evaluación de 0.0345 y un CF de evaluación de 0.9646.

6.4 Resultados de la Optimización

Para validar la etapa de optimización, varios experimentos fueron seleccionados para optimizar los parámetros utilizando AGs. Cada uno se escogió para representar las condiciones de corte y del proceso de maquinado. Cada corrida de los parámetros de corte en el AG se hizo dos veces, para confirmar repetitividad. Como indicadores de desempeño se seleccionaron el número de iteraciones de la función objetivo y el tiempo computacional. La optimización de los experimentos se muestra en las Tablas 6.5, 6.6, 6.7, 6.8, 6.9 y 6.10. Las Figuras 6.13, 6.14 y 6.15 muestran la optimización del Experimento #1 con las condiciones de herramienta Nueva, Semi-Nueva y Desgastada.

Experimento 1

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.1$, $Dtool=10$, $ae=2$, $HB=91$ y $Curv=-0.025$. El valor de Ra real de este experimento fue de 0.4531. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.25 (tipo de acabado Pulido).
- Primeramente se corre el AG con el modelo de ANN para herramienta Nueva usando fz como variable. Si el desempeño deseado no se cumple, se corre de nuevo el AG usando fz y ae como variables. Por último, si no se llega a un resultado satisfactorio, se vuelve a correr el AG usando fz , ae y $Dtool$ como variables. En cada experimento se considera primero la condición de herramienta Nueva, después Semi-Nueva, Semi-Desgastada y Desgastada, totalizando cuatro optimizaciones por experimento.
- Para la condición Nueva se optimizó en 2 segundos con 560 iteraciones de la función objetivo. Para la condición Semi-Nueva en 7.8 segundos con 3320 iteraciones. Para la condición Semi-Desgastada tomó 1.66 segundos y 340

iteraciones, y para la condición Desgastada se tomaron 5.013 segundos y 1560 iteraciones. El Número de iteraciones se incrementó en la condición de Semi-Nueva y Desgastada, debido a la ejecución del AG para los tres y dos parámetros respectivamente.

Tabla 6.5. Optimización del Experimento #1. La primera columna se refiere a los parámetros de corte iniciales, y el valor deseado de Ra . Para cada CTWC se muestra los resultados de las dos corridas. Los valores marcados son los cambios realizados a los parámetros de corte para lograr el valor deseado de Ra .

<i>PARAM</i>	<i>EXP. 1</i>	<i>NUEVA</i>		<i>SEMI-NUEVA</i>		<i>SEMI-DESGASTADA</i>		<i>DESGASTADA</i>	
<i>fz</i>	0.1	0.0716	0.0716	0.0777	0.079	0.075	0.075	0.056	0.058
<i>Dtool</i>	10	10	10	20	20	10	10	10	10
<i>ae</i>	2	2	2	3.388	3.247	2	2	2.129	2.136
<i>HB</i>	91	91	91	91	91	91	91	91	91
<i>Curv</i>	-0.025	-0.025	-0.025	-0.025	-0.025	-0.025	-0.025	-0.025	-0.025
<i>Ra</i>	0.25	0.2504	0.2497	0.2496	0.2497	0.2499	0.2499	0.25	0.249
<i>Iters</i>		560	480	3320	3580	340	360	1560	1380
<i>Tiempo (seg)</i>		2.005	1.877	7.835	8.309	1.66	1.411	5.013	4.614




Figura 6.13. Representación gráfica de la primera corrida del AG del Experimento #1 para la condición Nueva. Una solución óptima se encontró utilizando fz como única variable en el AG.

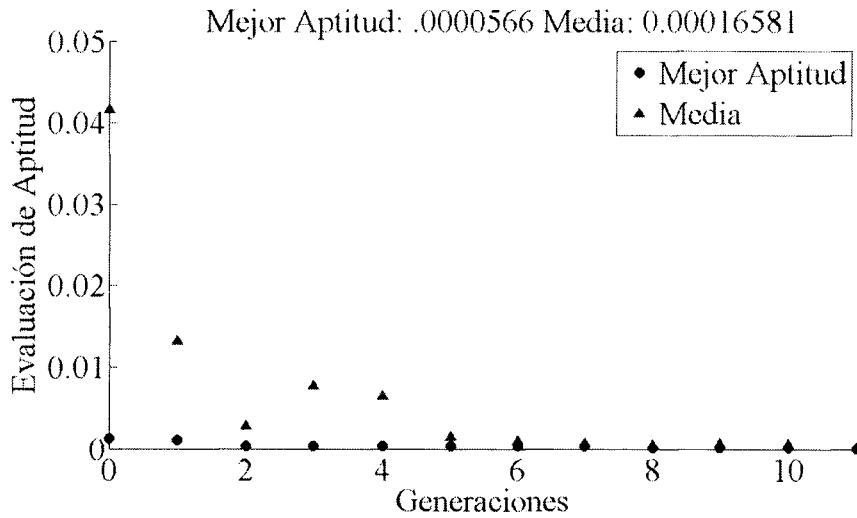


Figura 6.14. Representación gráfica de la tercera corrida del AG en el Experimento #1 para la condición de Semi-Nueva. Una solución óptima se logró utilizando fz , ae y $Dtool$ como variables.

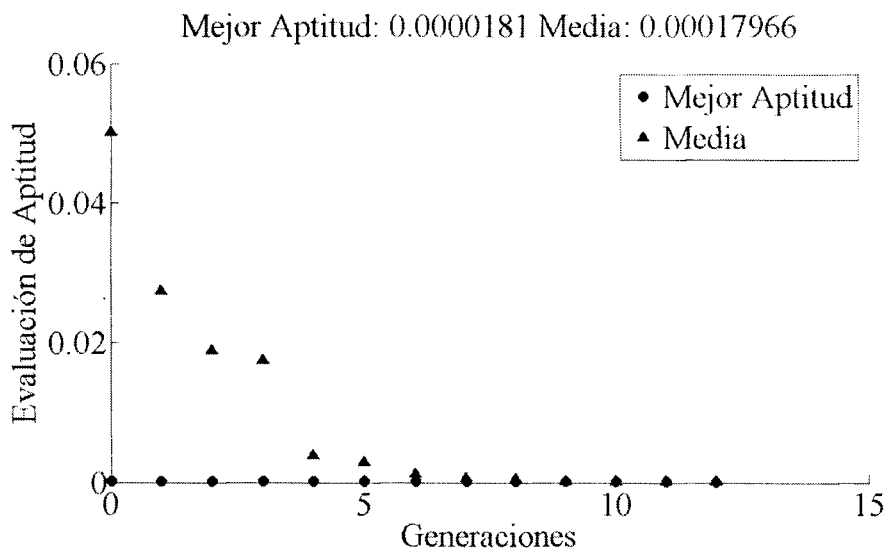


Figura 6.15. Representación gráfica de la segunda corrida de AG en el Experimento #1 para la condición Desgastada. Una solución óptima se logró utilizando fz y ae como variables.

Experimento 2

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.05$, $Dtool=16$, $ae=4$, $HB=94$ y $Curv=-0.025$. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.1 (tipo de acabado Espejo). El valor de Ra real de este experimento fue de 0.118.

- Para la condición Nueva se optimizó en 4.4 segundos con 1300 iteraciones de la función objetivo. Para la condición Semi-Nueva en 8.6 segundos con 3520 iteraciones. Para las condiciones Semi-Desgastada y Desgastada no se encontraron valores de corte óptimos.

Tabla 6.6. Optimización del Experimento #2. En las condiciones Semi-Desgastada y Desgastada no fue posible obtener la Ra deseada, que en este experimento requiere un valor muy pequeño.

<i>PARAM</i>	<i>EXP. 2</i>	<i>NUEVA</i>		<i>SEMI-NUEVA</i>		<i>SEMI-DESGASTADA</i>		<i>DESGASTADA</i>
<i>fz</i>	0.05	0.09	0.075	0.0569	0.05	NO FUE POSIBLE OPTIMIZAR		
<i>Dtool</i>	16	16	16	12	12			
<i>ae</i>	4	4.137	4.49	4.884	4.1268			
<i>HB</i>	94	94	94	94	94			
<i>Curv</i>	0.025	0.025	0.025	0.025	0.025			
<i>Ra</i>	0.1	0.1	0.1	0.099	0.099			
<i>Iters</i>		1300	1400	3520	3940			
<i>Tiempo (seg)</i>		4.406	4.519	8.682	9.508			

Experimento 3

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.05$, $Dtool=16$, $ae=2$, $HB=138$ y $Curv=-0.025$. El valor de Ra medido en el experimento fue de 0.1251. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.15 (tipo de acabado Pulido).
- Para la condición Nueva se optimizó en 1.37 segundos con 420 iteraciones de la función objetivo. Para la condición Semi-Nueva en 0.754 segundos con 220 iteraciones. Para la condición Semi-Desgastada se tomó 6.65 segundos y 3160 iteraciones, y la condición Desgastada no fue posible optimizar. Es importante observar que los valores óptimos no siempre implican disminuir el parámetro fz , en este caso el parámetro se incrementó para lograr la Ra deseada.

Tabla 6.7. Optimización del Experimento #3. La condición Desgastada no tuvo optimización.

<i>PARAM</i>	<i>EXP. 3</i>	<i>NUEVA</i>		<i>SEMI-NUEVA</i>		<i>SEMI-DESGASTADA</i>		<i>DESGASTADA</i>
<i>fz</i>	0.05	0.0983	0.0983	0.0503	0.0503	0.077	0.0788	NO FUE POSIBLE OPTIMIZAR
<i>Dtool</i>	16	16	16	16	16	20	20	
<i>ae</i>	2	2	2	2	2	4.109	4.054	
<i>HB</i>	138	138	138	138	138	138	138	
<i>Curv</i>	0.025	0.025	0.025	0.025	0.025	0.025	0.025	
<i>Ra</i>	0.15	0.149	0.1499	0.15	0.15	0.15	0.15	
<i>Iters</i>		420	380	220	200	3440	3160	
<i>Tiempo (seg)</i>		1.3726	1.295	0.754	0.668	9.352	6.656	

Experimento 4

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $f_z=0.13$, $D_{tool}=12$, $ae=3$, $HB=110$ y $Curv=0$. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.2 (tipo de acabado Espejo). El valor real de Ra del experimento fue de 0.356.
- Para la condición Nueva se optimizó en 1.79 segundos con 540 iteraciones de la función objetivo. Para la condición Semi-Nueva en 1.47 segundos con 460 iteraciones. Para la condición Semi-Desgastada tomó 5.08 segundos y 1520 iteraciones, y para la condición Desgastada se tomaron 0.725 segundos y 220 iteraciones. En los resultados obtenidos se puede observar que a medida que la herramienta fue presentado más desgaste del filo, el valor de parámetro f_z fue necesario disminuirlo para mantener la Ra deseada, solo en la caso de herramienta Semi-Desgastada fue necesario disminuir el valor del parámetro ae .

Tabla 6.8. Optimización del Experimento #4. La optimización se realizó en las cuatro condiciones de desgaste de la herramienta.

PARAM	EXP. 4	NUEVA		SEMI-NUEVA		SEMI-DESGASTADA		DESGASTADA	
f_z	0.13	0.0816	0.0816	0.078	0.078	0.0654	0.066	0.0505	0.0505
D_{tool}	12	12	12	12	12	12	12	12	12
ae	3	3	3	3	3	2.356	2.3	3	3
HB	110	110	110	110	110	110	110	110	110
$Curv$	0	0	0	0	0	0	0	0	0
Ra	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2
$Iters$		540	340	460	260	1520	1460	220	380
$Tiempo$ (seg)		1.798	1.461	1.479	0.882	5.0829	4.8098	0.725	1.26

Experimento 5

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $f_z=0.075$, $D_{tool}=12$, $ae=3$, $HB=154$ y $Curv=0$. El valor real de Ra que se obtuvo en el experimento fue de 0.2828. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.2 (tipo de acabado Espejo).
- Para la condición Nueva se optimizó en 5.57 segundos con 1640 iteraciones de la función objetivo. Para la condición Semi-Nueva se tomaron 5.74 segundos con 1780 iteraciones. Para la condición Semi-Desgastada tomó 5.45 segundos y 1540 iteraciones, y para la condición Desgastada se tomaron 1.46 segundos y 380 iteraciones.

Tabla 6.9. Optimización del Experimento #5. La optimización se realizó en las cuatro condiciones de desgaste de la herramienta.

<i>PARAM</i>	<i>EXP. 5</i>	<i>NUEVA</i>		<i>SEMI-NUEVA</i>		<i>SEMI-DESGASTADA</i>		<i>DESGASTADA</i>	
<i>fz</i>	0.075	0.049	0.053	0.0503	0.0503	0.066	0.0599	0.0566	0.0566
<i>Dtool</i>	12	12	12	12	12	12	12	12	12
<i>ae</i>	3	4.246	4.1944	4.437	4.477	1.985	2.22	3	3
<i>HB</i>	154	154	154	154	154	154	154	154	154
<i>Curv</i>	0	0	0	0	0	0	0	0	0
<i>Ra</i>	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2
<i>Iters</i>		1640	1380	1780	2020	1540	1500	380	360
<i>Tiempo (seg)</i>		5.571	5.166	5.748	6.803	5.456	5.107	1.46	1.212

Experimento 6

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.075$, $Dtool=12$, $ae=3$, $HB=111$ y $Curv=0.05$. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.1 (tipo de acabado Espejo). El valor real de Ra para este experimento fue de 0.1389.
- Para la condición Nueva se optimizó en 8.98 segundos con 3380 iteraciones de la función objetivo. Para la condición Semi-Nueva se tomaron 1.493 segundos con 500 iteraciones. Para la condición Semi-Desgastada tomó 1.593 segundos y 1440 iteraciones, y para la condición Desgastada no fue posible optimizar. En este tipo de prueba se demuestra que para una condición de herramienta desgastada no es posible lograr un acabado tipo espejo, esto es, la recomendación sería reemplazar la herramienta de corte.

Tabla 6.10. Optimización del Experimento #6. La optimización no se realizó en la condición Desgastada.

<i>PARAM</i>	<i>EXP. 6</i>	<i>NUEVA</i>		<i>SEMI-NUEVA</i>		<i>SEMI-DESGASTADA</i>		<i>DESGASTADA</i>
<i>fz</i>	0.075	0.0854	0.092	0.069	0.069	0.0623	0.063	NO FUE POSIBLE OPTIMIZAR
<i>Dtool</i>	12	16	16	12	12	12	12	
<i>ae</i>	3	4.489	4.867	3	3	4.09	4	
<i>HB</i>	111	111	111	111	111	111	111	
<i>Curv</i>	0.05	0.05	0.05	0.05	0.05	0.05	0.05	
<i>Ra</i>	0.1	0.1	0.1	0.1	0.1	0.1	0.1	
<i>Iters</i>		3380	3580	500	540	1440	1220	
<i>Tiempo (seg)</i>		8.987	8.46	1.493	1.593	5.109	4.08	

Pruebas de optimización adicionales se realizaron con experimentos que se hicieron con nuevos parámetros de corte, diferentes a los utilizados para entrenar la ANN. Estos resultados se muestran en las Tablas 6.11 y 6.12.

Experimento 7

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.075$, $D_{tool}=12$, $ae=3$, $HB=109$ y $Curv=0.037$. Se desea lograr un valor de Ra menor o igual a 0.1 (tipo de acabado Espejo) para la condición de desgaste Nueva. El valor de Ra medido en el experimento fue de 0.1756.
- Se optimizó en 8.64 segundos con 3400 iteraciones de la función objetivo.

Tabla 6.11. Optimización de un Experimento con datos nuevos en condición de herramienta Nueva. Se consideraron nuevos valores para los parámetros de corte, y se requirió un valor pequeño de Ra . Los tres parámetros de corte tuvieron que modificarse para lograr el valor de Ra deseado.

<i>PARAM</i>	<i>EXP. 7</i>	<i>NUEVA</i>	
<i>fz</i>	0.075	0.0922	0.091
<i>Dtool</i>	12	16	16
<i>ae</i>	3	4.98	4.967
<i>HB</i>	109	109	109
<i>Curv</i>	0.037	0.037	0.037
<i>Ra</i>	0.1	0.099	0.1
<i>Iters</i>		3400	3480
<i>Tiempo (seg)</i>		8.645	8.185

Experimento 8

- Para el maquinado de la pieza, se parte de los siguientes parámetros: $fz=0.04$, $D_{tool}=12$, $ae=4$, $HB=94$ y $Curv=0.0385$. Se desea encontrar los valores óptimos para lograr un valor de Ra menor o igual a 0.2 (tipo de acabado Espejo) para la condición de desgaste Nueva. El valor de Ra real que se obtuvo en el experimento fue de 0.3218.
- Se optimizó en 1.489 segundos con 480 iteraciones de la función objetivo. Nuevamente se observa que el valor del parámetro fz se incrementó para lograr el valor de Ra deseado.

Por medio de los resultados obtenidos, se pueden hacer varias observaciones:

- Comparando los valores reales de Ra que se midieron en los experimentos, y los valores de Ra que resultaron de la optimización, se puede ver que el AG presenta una solución factible, práctica y con buenos resultados en la selección de parámetros de corte óptimos.

Tabla 6.12. Optimización de un Experimento con datos nuevos en condición de herramienta Semi-Desgastada. Esta optimización solo requirió del cambio de fz para poder llegar al resultado deseado.

<i>PARAM</i>	<i>EXP. 8</i>	<i>NUEVA</i>	
<i>fz</i>	0.04	0.0741	0.0739
<i>Dtool</i>	12	12	12
<i>ae</i>	4	4	4
<i>HB</i>	94	94	94
<i>Curv</i>	0.0385	0.0385	0.0385
<i>Ra</i>	0.2	0.199	0.199
<i>Iters</i>		480	500
<i>Tiempo (seg)</i>		1.489	1.639

- No todos los problemas de optimización pudieron resolverse, específicamente con condiciones Semi-Desgastada y Desgastada. Esto es constante sobre todo cuando se requiere un valor muy pequeño de Ra .
- Al realizar la optimización con varios parámetros, el tiempo e iteraciones del programa se incrementa, ya que un nuevo AG se ejecuta cada vez.
- Es importante observar que los valores óptimos no siempre implican disminuir el parámetro fz , como en el Experimento #3. En este caso el parámetro se incrementó para lograr la Ra deseada.
- Existen casos en los que a medida que la herramienta presenta más desgaste en el filo, el parámetro fz debe disminuir, para mantener la Ra deseada, como en el Experimento #4.
- En casos en los que una optimización para un acabado de mayor calidad (espejo) no es posible para las condiciones de desgaste mayores (Semi-Desgastada y Desgastada), se recomienda reemplazar la herramienta de corte.

CAPÍTULO 7

CONCLUSIONES Y TRABAJO FUTURO

En esta investigación se obtuvieron los siguientes resultados:

- Se propuso una estructura para predecir Ra en un proceso de fresado HSM. Esta estructura utiliza cinco parámetros de corte como entrada y el valor de Ra como salida, con un algoritmo de Retro Propagación Resiliente. Después de evaluar varias opciones para el número de neuronas en la capa oculta, se determinó que diez neuronas en la capa oculta presenta el mejor desempeño. Esta estructura mostró excelentes resultados en la fase de entrenamiento para cada condición de herramienta de corte (MSE de 0.0066 para condición Nueva, 0.0101 para condición Semi-Nueva, 0.0144 para condición Semi-Desgastada y 0.0122 para condición Desgastada). Para la fase de evaluación el MSE fue de 0.0113 para condición Nueva, 0.215 para condición Semi-Nueva, 0.0422 para condición Semi-Desgastada y 0.0124 para condición Desgastada. Se logró una validación excelente con datos nuevos. Estos muestran la habilidad predictiva cuando las condiciones de corte son diferentes a las usuales. Para la condición Nueva, el MSE fue de 0.000168, para la condición Semi-Nueva, de 0.0251, para la condición Semi-Desgastada de 0.1006 y 0.0389 para la condición Desgastada.
- Se propuso otra estructura de ANN para predecir el valor de Ra en En-Línea, esto es durante el proceso de mecanizado. Esta estructura cuenta con los cinco parámetros de corte más siete señales del proceso caracterizadas por medio de los coeficientes Cepstrales (MFCC). Después de analizar varias señales de proceso se determinó que la Fuerza de corte en la dirección X proporciona mejores resultados. La estructura propuesta fue 12x12x1 y también se utilizó el algoritmo de Retro Propagación Resiliente para su entrenamiento. Los promedios de los indicadores de desempeño para esta estructura fueron 0.013 de MSE en entrenamiento, 0.029 para evaluación, 0.953 de CF en entrenamiento y 0.894 en evaluación. Esta propuesta es capaz de predecir la Ra con robustez sin depender de la condición de la herramienta de corte. Con la validación de datos nuevos, esta estructura pudo predecir excelentemente los valores de Ra , con un MSE de entrenamiento de 0.01148, un MSE de evaluación de 0.002018, un CF en entrenamiento de 0.9592 y un CF en evaluación de 0.9634.
- Se diseñó una estructura de ANN para detectar la condición de desgaste en la herramienta de corte. Esta estructura utiliza los cinco parámetros de corte, además de siete señales de MFCC que caracterizan las señales acústicas del husillo. Esta estructura tuvo un desempeño altamente eficaz en la detección de la CTWC, con un MSE de entrenamiento de 0.0, y un MSE de evaluación de 0.0182. Esto significa que en entrenamiento se reprodujo sin error la detección de CTWC, y en evaluación existieron 3 o 4 casos de error, entre aproximadamente 140 experimentos. En la fase de validación con datos de experimentos nuevos, la estructura mantuvo el buen desempeño, con un MSE de evaluación de 0.024 y un CF de evaluación de 0.9749.

- Se modeló un sistema de tres etapas para optimizar el proceso de maquinado. La estructura de ANN Pre-Proceso provee del modelo de formación de Ra en el fresado HSM, y un AG encuentra la solución óptima de parámetros de corte para obtener el valor deseado de Ra .

Las siguientes son contribuciones al área de mecanizado, logradas en esta investigación:

- Se logró incrementar el desempeño de un Modelo Pre-Proceso para predicción de Ra , al utilizar un algoritmo de entrenamiento diferente (Retro Propagación Resiliente). Las funciones de transferencia recomendadas para este modelo son Logarítmica Sigmoidal y Lineal.
- Se demostró que el número de neuronas en la capa oculta de un ANN puede considerarse como n , $2n$, $2n+1$, siendo el más adecuado $2n$, y donde n es el número de variables en la capa de entrada.
- Se propuso un Modelo En-Línea para predicción de Ra que permite determinar con bastante exactitud el valor de rugosidad durante toda la vida útil de la herramienta de corte, y también con datos de experimentos nuevos.
- Se obtuvo un Modelo para Detección de CTWC utilizando señales de proceso de emisores acústicos. Este modelo proporciona excelentes resultados aún con datos obtenidos de nuevos experimentos.
- Se propuso una secuencia de optimización, cambiando sólo el mínimo de parámetros de corte posible. Esto se logra realizando un sistema de tres etapas. Primero el AG optimiza con cuatro parámetros fijos, variando solamente fz . Si no se llega a una solución, se añade ae , y en una tercera etapa, se añade $Dtool$.
- Se propuso una nueva función objetivo, en la cual se asegura que el AG llegue a una solución óptima, no a un mínimo valor de Ra . Esto es porque en la función objetivo de minimización el AG puede encontrar un valor de Ra menor al requerido, y esto no es siempre deseado, ya que los parámetros de corte pueden requerir cambios significativos para lograr este resultado.
- Esta investigación provee de una manera de tomar ventaja de la vida útil de la herramienta de corte, considerándola en el proceso de optimización, y es capaz de encontrar una solución óptima en valores pequeños de Ra (0.20-0.25) aún con la condición de herramienta Semi-Desgastada o Desgastada.
- El modelo de optimización utilizando un AG y los modelos de ANN para cada condición de desgaste resulta en una herramienta valiosa para calcular los parámetros de corte para un valor deseado de Ra , considerando diferentes herramientas de corte, diversos tipos de aleaciones de aluminio y diversas geometrías para el maquinado. Otros trabajos consultados solo consideran un tipo de herramienta asociada a un material específico y solo consideran trayectorias rectas.

Como trabajo futuro, se pueden sugerir las siguientes líneas de investigación:

- Profundizar en la investigación con señales del proceso referentes a señales acústicas, utilizándolas también en la predicción de Ra y no solamente en la detección de CTWC.
- Integrar la predicción de Ra En-Línea con la detección de condición de desgaste en la herramienta de corte.
- Desarrollar modelos menos complejos de ANN, optimizando su arquitectura, de manera que se pueda realizar un entrenamiento En-Línea.
- Probar nuevas estructuras y algoritmos de entrenamiento para la predicción del valor de Ra utilizando ANN.
- Implementar el algoritmo de optimización a un sistema de monitoreo y supervisión de un CNC para fresado periférico en HSM.

APÉNDICES

ÍNDICE DE TABLAS

Tabla A.1. Resultados preliminares de ANN para estructura 5x2x1 en Pre-Proceso.	66
Tabla A.2. Resultados preliminares de ANN para estructura 5x5x1 en Pre-Proceso.	66
Tabla A.3. Resultados preliminares de ANN para estructura 5x10x1 en Pre-Proceso.	67
Tabla A.4. Resultados preliminares de ANN para estructura 5x11x1 en Pre-Proceso.	67
Tabla A.5. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE.	68
Tabla A.6. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE.	68
Tabla A.7. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE.	69
Tabla A.8. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE.	69
Tabla A.9. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE.	70
Tabla A.10. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE.	70
Tabla A.11. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE.	71
Tabla A.12. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE.	71
Tabla A.13. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE.	72
Tabla A.14. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE.	72
Tabla A.15. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE.	73

Tabla A.16. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE.	73
Tabla A.17. Resultados para la predicción de <i>Ra</i> En-Línea utilizando los parámetros de corte y siete valores de MFCC de la aceleración en X.	74
Tabla A.18. Resultados para la predicción de <i>Ra</i> En-Línea utilizando los parámetros de corte y siete valores de MFCC de la aceleración en Y.	75
Tabla A.19. Resultados para la predicción de <i>Ra</i> En-Línea utilizando los parámetros de corte y siete valores de MFCC de la fuerza en X.	76
Tabla A.20. Resultados para la predicción de <i>Ra</i> En-Línea utilizando los parámetros de corte y siete valores de MFCC de la fuerza en Y.	77
Tabla A.21. Resultados para la predicción Pre-Proceso de <i>Ra</i> utilizando la Nueva condición de desgaste en la herramienta.	79
Tabla A.22. Resultados para la predicción Pre-Proceso de <i>Ra</i> utilizando la Semi-Nueva condición de desgaste en la herramienta.	79
Tabla A.23. Resultados para la predicción Pre-Proceso de <i>Ra</i> utilizando la Semi-Desgastada condición de desgaste en la herramienta.	80
Tabla A.24. Resultados para la predicción Pre-Proceso de <i>Ra</i> utilizando la Desgastada condición de desgaste en la herramienta.	81
Tabla B.1. Experimentos con nuevos parámetros de validación para la estructura de ANN Pre-Proceso.	82

APÉNDICE A

RESULTADOS PARA MODELOS DE ANN

Tabla A.1. Resultados preliminares de ANN para estructura 5x2x1 en Pre-Proceso. Se comparan dos algoritmos de entrenamiento: GDA (Descenso por Gradiente) y RPROP (Retro Propagación Resiliente).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.011	0.010	0.016	0.013	0.011	0.010	0.013	0.015	0.008	0.011	0.012	0.002
	MSE EVAL	0.011	0.014	0.052	0.027	0.012	0.010	0.049	0.024	0.019	0.013	0.023	0.016
	CF ENT	0.968	0.965	0.944	0.953	0.962	0.971	0.962	0.955	0.975	0.965	0.962	0.009
	CF EVAL	0.957	0.977	0.859	0.930	0.972	0.946	0.804	0.926	0.938	0.960	0.927	0.055
GDA	MSE ENT	0.121	0.127	0.102	0.080	0.089	0.134	0.113	0.067	0.071	0.096	0.100	0.023
	MSE EVAL	0.070	0.216	0.201	0.200	0.154	0.045	0.053	0.210	0.191	0.124	0.146	0.068
	CF ENT	0.942	0.919	0.941	0.950	0.947	0.937	0.948	0.969	0.965	0.951	0.947	0.014
	CF EVAL	0.956	0.950	0.915	0.925	0.944	0.965	0.965	0.906	0.899	0.935	0.936	0.024

Tabla A.2. Resultados preliminares de ANN para estructura 5x5x1 en Pre-Proceso. Se comparan dos algoritmos de entrenamiento: GDA (Descenso por Gradiente) y RPROP (Retro Propagación Resiliente).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.007	0.006	0.005	0.004	0.009	0.007	0.007	0.006	0.005	0.006	0.006	0.001
	MSE EVAL	0.008	0.012	0.019	0.025	0.015	0.010	0.010	0.030	0.017	0.012	0.016	0.007
	CF ENT	0.980	0.980	0.982	0.986	0.967	0.979	0.980	0.983	0.984	0.981	0.980	0.005
	CF EVAL	0.968	0.972	0.949	0.938	0.966	0.946	0.963	0.919	0.946	0.963	0.953	0.016
GDA	MSE ENT	0.067	0.039	0.050	0.027	0.043	0.065	0.070	0.040	0.046	0.058	0.050	0.014
	MSE EVAL	0.063	0.124	0.130	0.217	0.114	0.045	0.198	0.346	0.126	0.068	0.143	0.090
	CF ENT	0.968	0.976	0.972	0.984	0.975	0.970	0.968	0.981	0.978	0.971	0.974	0.005
	CF EVAL	0.961	0.959	0.944	0.915	0.958	0.964	0.853	0.858	0.934	0.965	0.931	0.043

Tabla A.3. Resultados preliminares de ANN para estructura 5x10x1 en Pre-Proceso. Se comparan dos algoritmos de entrenamiento: GDA (Descenso por Gradiente) y RPROP (Retro Propagación Resiliente).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.007	0.006	0.005	0.003	0.006	0.007	0.006	0.005	0.005	0.006	0.005	0.001
	MSE EVAL	0.007	0.012	0.021	0.027	0.011	0.009	0.011	0.014	0.015	0.012	0.014	0.006
	CF ENT	0.981	0.980	0.984	0.989	0.979	0.981	0.982	0.985	0.985	0.983	0.983	0.003
	CF EVAL	0.973	0.972	0.946	0.935	0.974	0.954	0.957	0.959	0.952	0.965	0.959	0.013
GDA	MSE ENT	0.057	0.036	0.049	0.025	0.041	0.064	0.057	0.034	0.035	0.056	0.045	0.013
	MSE EVAL	0.048	0.121	0.139	0.216	0.105	0.042	0.064	0.155	0.121	0.063	0.107	0.055
	CF ENT	0.973	0.978	0.972	0.985	0.976	0.971	0.974	0.984	0.983	0.972	0.977	0.005
	CF EVAL	0.971	0.958	0.940	0.917	0.961	0.967	0.954	0.928	0.938	0.968	0.950	0.018

Tabla A.4. Resultados preliminares de ANN para estructura 5x11x1 en Pre-Proceso. Se comparan dos algoritmos de entrenamiento: GDA (Descenso por Gradiente) y RPROP (Retro Propagación Resiliente).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.006	0.006	0.005	0.004	0.006	0.007	0.006	0.005	0.005	0.006	0.005	0.001
	MSE EVAL	0.008	0.012	0.020	0.026	0.011	0.009	0.012	0.028	0.014	0.012	0.015	0.007
	CF ENT	0.981	0.980	0.984	0.987	0.979	0.981	0.982	0.985	0.986	0.982	0.983	0.003
	CF EVAL	0.970	0.973	0.949	0.936	0.974	0.953	0.953	0.923	0.952	0.963	0.954	0.017
GDA	MSE ENT	0.057	0.036	0.049	0.024	0.042	0.065	0.058	0.035	0.034	0.054	0.045	0.013
	MSE EVAL	0.050	0.114	0.143	0.221	0.112	0.057	0.064	0.186	0.124	0.064	0.114	0.058
	CF ENT	0.973	0.978	0.972	0.985	0.975	0.970	0.974	0.984	0.983	0.973	0.977	0.006
	CF EVAL	0.969	0.961	0.938	0.915	0.960	0.957	0.954	0.915	0.936	0.967	0.947	0.020

Tabla A.5. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.006	0.006	0.005	0.004	0.006	0.007	0.006	0.005	0.005	0.006	0.005	0.001
	MSE EVAL	0.008	0.012	0.020	0.026	0.011	0.009	0.012	0.028	0.014	0.012	0.015	0.007
	CF ENT	0.981	0.980	0.984	0.987	0.979	0.981	0.982	0.985	0.986	0.982	0.983	0.003
	CF EVAL	0.970	0.973	0.949	0.936	0.974	0.953	0.953	0.923	0.952	0.963	0.954	0.017
GDA	MSE ENT	0.057	0.036	0.049	0.024	0.042	0.065	0.058	0.035	0.034	0.054	0.045	0.013
	MSE EVAL	0.050	0.114	0.143	0.221	0.112	0.057	0.064	0.186	0.124	0.064	0.114	0.058
	CF ENT	0.973	0.978	0.972	0.985	0.975	0.970	0.974	0.984	0.983	0.973	0.977	0.006
	CF EVAL	0.969	0.961	0.938	0.915	0.960	0.957	0.954	0.915	0.936	0.967	0.947	0.020

Tabla A.6. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.067	0.071	0.076	0.070	0.069	0.058	0.059	0.071	0.053	0.042	0.064	0.010
	MSE EVAL	0.056	0.112	0.207	0.159	0.048	0.119	0.148	0.077	0.168	0.179	0.127	0.054
	CF ENT	0.967	0.960	0.959	0.964	0.962	0.965	0.971	0.965	0.972	0.979	0.967	0.006
	CF EVAL	0.971	0.953	0.916	0.916	0.984	0.955	0.923	0.964	0.921	0.898	0.940	0.029
GDA	MSE ENT	0.033	0.024	0.027	0.033	0.029	0.039	0.030	0.026	0.053	0.018	0.031	0.010
	MSE EVAL	0.037	0.019	0.034	0.061	0.034	0.043	0.024	0.041	0.063	0.035	0.039	0.014
	CF ENT	0.896	0.917	0.907	0.893	0.900	0.860	0.907	0.919	0.816	0.946	0.896	0.036
	CF EVAL	0.872	0.946	0.899	0.840	0.906	0.884	0.930	0.860	0.803	0.874	0.881	0.042

Tabla A.7. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.055	0.053	0.028	0.025	0.066	0.036	0.034	0.058	0.025	0.019	0.040	0.017
	MSE EVAL	0.058	0.081	0.173	0.136	0.054	0.113	0.111	0.046	0.198	0.183	0.115	0.056
	CF ENT	0.973	0.971	0.985	0.987	0.963	0.979	0.983	0.971	0.987	0.991	0.979	0.009
	CF EVAL	0.972	0.965	0.943	0.928	0.979	0.956	0.938	0.980	0.915	0.894	0.947	0.029
GDA	MSE ENT	0.007	0.006	0.005	0.004	0.008	0.006	0.006	0.007	0.004	0.003	0.006	0.002
	MSE EVAL	0.009	0.013	0.016	0.018	0.007	0.011	0.016	0.007	0.019	0.025	0.014	0.006
	CF ENT	0.978	0.982	0.985	0.987	0.974	0.980	0.982	0.979	0.987	0.991	0.982	0.005
	CF EVAL	0.971	0.965	0.964	0.944	0.983	0.971	0.956	0.977	0.948	0.915	0.958	0.020

Tabla A.8. Resultados de ANN para estructura 5x5x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.056	0.056	0.028	0.036	0.062	0.039	0.035	0.058	0.029	0.018	0.042	0.015
	MSE EVAL	0.055	0.083	0.181	0.166	0.044	0.112	0.117	0.045	0.155	0.187	0.115	0.056
	CF ENT	0.973	0.969	0.985	0.982	0.966	0.977	0.983	0.971	0.985	0.991	0.978	0.008
	CF EVAL	0.973	0.965	0.936	0.912	0.983	0.957	0.936	0.980	0.936	0.892	0.947	0.030
GDA	MSE ENT	0.008	0.005	0.005	0.004	0.008	0.006	0.006	0.007	0.004	0.003	0.006	0.001
	MSE EVAL	0.008	0.014	0.021	0.015	0.006	0.012	0.012	0.008	0.020	0.024	0.014	0.006
	CF ENT	0.977	0.982	0.984	0.987	0.974	0.981	0.982	0.979	0.986	0.990	0.982	0.005
	CF EVAL	0.974	0.964	0.956	0.951	0.975	0.968	0.963	0.976	0.943	0.918	0.959	0.019

Tabla A.9. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.057	0.052	0.028	0.025	0.061	0.038	0.034	0.059	0.025	0.019	0.040	0.016
	MSE EVAL	0.054	0.079	0.291	0.135	0.048	0.117	0.114	0.052	0.189	0.192	0.127	0.078
	CF ENT	0.972	0.971	0.985	0.987	0.966	0.978	0.983	0.971	0.987	0.991	0.979	0.009
	CF EVAL	0.974	0.967	0.862	0.929	0.982	0.955	0.937	0.977	0.919	0.888	0.939	0.040
GDA	MSE ENT	0.019	0.013	0.010	0.021	0.021	0.015	0.016	0.012	0.011	0.005	0.014	0.005
	MSE EVAL	0.031	0.017	0.034	0.033	0.024	0.026	0.024	0.018	0.047	0.030	0.028	0.009
	CF ENT	0.942	0.957	0.966	0.934	0.928	0.950	0.952	0.963	0.964	0.986	0.954	0.017
	CF EVAL	0.889	0.953	0.901	0.909	0.935	0.939	0.920	0.939	0.847	0.897	0.913	0.031

Tabla A.10. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.063	0.058	0.039	0.049	0.064	0.055	0.043	0.099	0.037	0.024	0.053	0.021
	MSE EVAL	0.062	0.104	0.181	0.188	0.050	0.140	0.119	0.139	0.154	0.155	0.129	0.046
	CF ENT	0.969	0.968	0.979	0.975	0.964	0.967	0.979	0.950	0.981	0.988	0.972	0.011
	CF EVAL	0.966	0.956	0.929	0.905	0.983	0.949	0.934	0.926	0.933	0.910	0.939	0.025
GDA	MSE ENT	0.026	0.020	0.026	0.025	0.026	0.041	0.022	0.043	0.021	0.028	0.028	0.008
	MSE EVAL	0.026	0.018	0.047	0.043	0.033	0.072	0.020	0.062	0.038	0.044	0.040	0.018
	CF ENT	0.918	0.937	0.914	0.921	0.913	0.850	0.933	0.866	0.931	0.912	0.909	0.029
	CF EVAL	0.908	0.946	0.859	0.856	0.912	0.799	0.943	0.753	0.883	0.832	0.869	0.062

Tabla A.11. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.053	0.050	0.025	0.021	0.057	0.034	0.031	0.055	0.022	0.016	0.037	0.016
	MSE EVAL	0.062	0.072	0.423	0.149	0.055	0.119	0.117	0.049	0.189	0.181	0.141	0.111
	CF ENT	0.974	0.972	0.986	0.990	0.968	0.980	0.985	0.973	0.989	0.992	0.981	0.009
	CF EVAL	0.973	0.970	0.794	0.921	0.979	0.954	0.936	0.977	0.917	0.896	0.932	0.056
GDA	MSE ENT	0.007	0.005	0.004	0.004	0.007	0.005	0.006	0.007	0.004	0.002	0.005	0.002
	MSE EVAL	0.008	0.014	0.048	0.017	0.007	0.012	0.012	0.008	0.020	0.026	0.017	0.012
	CF ENT	0.980	0.983	0.986	0.988	0.977	0.982	0.982	0.981	0.988	0.993	0.984	0.005
	CF EVAL	0.976	0.964	0.855	0.947	0.982	0.968	0.963	0.975	0.946	0.912	0.949	0.039

Tabla A.12. Resultados de ANN para estructura 5x10x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.054	0.048	0.026	0.022	0.057	0.035	0.030	0.055	0.023	0.015	0.036	0.016
	MSE EVAL	0.055	0.079	0.227	0.143	0.047	0.120	0.112	0.049	0.190	0.190	0.121	0.065
	CF ENT	0.974	0.973	0.986	0.989	0.968	0.979	0.985	0.973	0.988	0.993	0.981	0.008
	CF EVAL	0.974	0.966	0.899	0.924	0.982	0.954	0.937	0.978	0.919	0.891	0.942	0.033
GDA	MSE ENT	0.007	0.005	0.004	0.004	0.007	0.005	0.006	0.007	0.003	0.002	0.005	0.002
	MSE EVAL	0.008	0.013	0.018	0.017	0.008	0.012	0.012	0.008	0.021	0.026	0.014	0.006
	CF ENT	0.980	0.984	0.986	0.988	0.976	0.982	0.983	0.980	0.990	0.993	0.984	0.005
	CF EVAL	0.976	0.967	0.957	0.946	0.981	0.970	0.963	0.975	0.944	0.911	0.959	0.021

Tabla A.13. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando GDA y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.058	0.052	0.028	0.024	0.060	0.038	0.033	0.058	0.024	0.017	0.039	0.016
	MSE EVAL	0.055	0.074	0.174	0.140	0.048	0.115	0.103	0.045	0.183	0.179	0.112	0.055
	CF ENT	0.972	0.971	0.985	0.988	0.967	0.978	0.984	0.971	0.988	0.992	0.979	0.009
	CF EVAL	0.972	0.969	0.940	0.926	0.982	0.956	0.941	0.980	0.922	0.897	0.948	0.028
GDA	MSE ENT	0.013	0.011	0.009	0.007	0.015	0.009	0.012	0.015	0.013	0.010	0.011	0.003
	MSE EVAL	0.012	0.023	0.029	0.020	0.024	0.015	0.015	0.021	0.030	0.027	0.022	0.006
	CF ENT	0.961	0.965	0.969	0.978	0.950	0.970	0.965	0.954	0.960	0.971	0.964	0.008
	CF EVAL	0.958	0.938	0.925	0.936	0.939	0.962	0.951	0.926	0.911	0.901	0.935	0.020

Tabla A.14. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando GDA y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.068	0.053	0.037	0.035	0.083	0.041	0.064	0.075	0.052	0.021	0.053	0.020
	MSE EVAL	0.056	0.078	0.347	0.162	0.062	0.093	0.162	0.084	0.128	0.172	0.134	0.086
	CF ENT	0.967	0.971	0.980	0.983	0.953	0.976	0.968	0.963	0.974	0.990	0.972	0.010
	CF EVAL	0.968	0.967	0.832	0.915	0.975	0.965	0.912	0.958	0.946	0.900	0.934	0.045
GDA	MSE ENT	0.034	0.037	0.019	0.020	0.023	0.023	0.023	0.038	0.052	0.050	0.032	0.012
	MSE EVAL	0.041	0.040	0.034	0.037	0.035	0.046	0.029	0.067	0.071	0.075	0.048	0.017
	CF ENT	0.893	0.871	0.938	0.936	0.922	0.918	0.928	0.881	0.822	0.838	0.895	0.041
	CF EVAL	0.863	0.881	0.899	0.891	0.898	0.885	0.898	0.737	0.773	0.696	0.842	0.077

Tabla A.15. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando RPROP y funciones de transferencia TAN-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.054	0.049	0.025	0.021	0.056	0.035	0.031	0.056	0.020	0.014	0.036	0.016
	MSE EVAL	0.061	0.072	0.273	0.151	0.050	0.115	0.113	0.046	0.196	0.182	0.126	0.074
	CF ENT	0.974	0.973	0.986	0.989	0.969	0.979	0.985	0.972	0.990	0.993	0.981	0.009
	CF EVAL	0.971	0.970	0.873	0.920	0.980	0.955	0.936	0.979	0.915	0.895	0.940	0.038
GDA	MSE ENT	0.007	0.005	0.004	0.004	0.007	0.006	0.006	0.007	0.004	0.003	0.005	0.002
	MSE EVAL	0.008	0.013	0.015	0.019	0.010	0.012	0.012	0.008	0.020	0.025	0.014	0.006
	CF ENT	0.979	0.984	0.986	0.988	0.977	0.981	0.983	0.979	0.989	0.993	0.984	0.005
	CF EVAL	0.975	0.965	0.966	0.941	0.976	0.968	0.964	0.956	0.946	0.914	0.956	0.020

Tabla A.16. Resultados de ANN para estructura 5x11x1 en Pre-Proceso utilizando RPROP y funciones de transferencia LOG-PURE. Se comparan dos métodos de normalización: NORM A (media=0, desv. std.= 1) y NORM B (exponencial).

ALG	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
RPROP	MSE ENT	0.053	0.048	0.025	0.023	0.056	0.035	0.029	0.053	0.020	0.013	0.036	0.016
	MSE EVAL	0.053	0.070	0.174	0.139	0.048	0.118	0.126	0.052	0.188	0.188	0.116	0.057
	CF ENT	0.974	0.973	0.986	0.988	0.969	0.979	0.986	0.974	0.990	0.994	0.981	0.009
	CF EVAL	0.974	0.971	0.946	0.927	0.981	0.955	0.930	0.975	0.921	0.893	0.947	0.029
GDA	MSE ENT	0.007	0.005	0.004	0.004	0.008	0.005	0.005	0.007	0.004	0.002	0.005	0.002
	MSE EVAL	0.008	0.013	0.029	0.017	0.007	0.012	0.011	0.008	0.020	0.027	0.015	0.008
	CF ENT	0.980	0.984	0.986	0.988	0.975	0.982	0.984	0.981	0.989	0.994	0.984	0.005
	CF EVAL	0.975	0.966	0.937	0.946	0.983	0.969	0.963	0.975	0.946	0.911	0.957	0.022

Tabla A.17. Resultados para la predicción de *Ra* En-Línea utilizando los parámetros de corte y siete valores de MFCC de la aceleración en X. Cuatro números de neuronas en la capa oculta se probaron (6, 12, 24 y 25).

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
12x6x1	MSE ENT	0.022	0.023	0.019	0.021	0.023	0.021	0.020	0.022	0.020	0.020	0.021	0.001
	CF ENT	0.915	0.918	0.929	0.925	0.920	0.924	0.928	0.922	0.928	0.928	0.924	0.005
	MSE EVAL	0.042	0.032	0.031	0.034	0.033	0.040	0.042	0.040	0.039	0.032	0.036	0.004
	CF EVAL	0.868	0.885	0.894	0.868	0.879	0.856	0.849	0.849	0.858	0.879	0.868	0.016
12x12x1	MSE ENT	0.014	0.014	0.011	0.014	0.014	0.012	0.012	0.013	0.013	0.013	0.013	0.001
	CF ENT	0.946	0.950	0.959	0.951	0.950	0.959	0.957	0.953	0.954	0.956	0.953	0.004
	MSE EVAL	0.041	0.030	0.048	0.036	0.033	0.035	0.045	0.040	0.035	0.033	0.038	0.006
	CF EVAL	0.871	0.895	0.838	0.865	0.886	0.876	0.845	0.858	0.876	0.877	0.869	0.018
12x24x1	MSE ENT	0.008	0.008	0.005	0.006	0.007	0.007	0.006	0.007	0.006	0.007	0.007	0.001
	CF ENT	0.969	0.973	0.982	0.978	0.975	0.977	0.977	0.974	0.979	0.976	0.976	0.003
	MSE EVAL	0.048	0.030	0.048	0.040	0.038	0.044	0.047	0.035	0.045	0.043	0.042	0.006
	CF EVAL	0.852	0.900	0.840	0.850	0.866	0.840	0.840	0.875	0.840	0.836	0.854	0.021
12x25x1	MSE ENT	0.007	0.007	0.007	0.007	0.007	0.006	0.007	0.006	0.007	0.006	0.007	0.000
	CF ENT	0.972	0.975	0.975	0.974	0.977	0.980	0.976	0.978	0.976	0.978	0.976	0.002
	MSE EVAL	0.046	0.037	0.040	0.039	0.043	0.047	0.039	0.038	0.046	0.036	0.041	0.004
	CF EVAL	0.859	0.874	0.872	0.857	0.860	0.840	0.862	0.866	0.838	0.872	0.860	0.012

Tabla A.18. Resultados para la predicción de R_a En-Línea utilizando los parámetros de corte y siete valores de MFCC de la aceleración en Y. Cuatro números de neuronas en la capa oculta se probaron (6, 12, 24 y 25).

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
12x6x1	MSE ENT	0.019	0.017	0.021	0.018	0.018	0.020	0.018	0.018	0.020	0.020	0.019	0.001
	CF ENT	0.924	0.938	0.923	0.936	0.937	0.927	0.934	0.936	0.929	0.928	0.931	0.006
	MSE EVAL	0.036	0.031	0.034	0.034	0.033	0.034	0.032	0.025	0.040	0.037	0.034	0.004
	CF EVAL	0.887	0.895	0.883	0.874	0.880	0.874	0.881	0.908	0.853	0.857	0.879	0.016
12x12x1	MSE ENT	0.012	0.012	0.013	0.012	0.012	0.011	0.011	0.013	0.013	0.012	0.012	0.001
	CF ENT	0.953	0.957	0.952	0.958	0.958	0.961	0.962	0.956	0.955	0.960	0.957	0.003
	MSE EVAL	0.034	0.028	0.029	0.037	0.033	0.033	0.030	0.034	0.033	0.038	0.033	0.003
	CF EVAL	0.893	0.907	0.902	0.866	0.880	0.882	0.891	0.880	0.881	0.856	0.884	0.016
12x24x1	MSE ENT	0.006	0.008	0.006	0.007	0.008	0.006	0.007	0.007	0.006	0.006	0.007	0.001
	CF ENT	0.977	0.972	0.977	0.976	0.974	0.977	0.976	0.974	0.977	0.978	0.976	0.002
	MSE EVAL	0.040	0.028	0.042	0.043	0.037	0.040	0.038	0.041	0.031	0.043	0.038	0.005
	CF EVAL	0.877	0.903	0.862	0.853	0.865	0.854	0.872	0.860	0.888	0.847	0.868	0.017
12x25x1	MSE ENT	0.006	0.007	0.006	0.006	0.007	0.008	0.006	0.006	0.006	0.005	0.007	0.001
	CF ENT	0.975	0.974	0.977	0.978	0.976	0.973	0.979	0.977	0.979	0.982	0.977	0.003
	MSE EVAL	0.037	0.035	0.037	0.042	0.038	0.041	0.035	0.035	0.043	0.037	0.038	0.003
	CF EVAL	0.886	0.887	0.879	0.860	0.864	0.858	0.884	0.880	0.844	0.862	0.870	0.015

Tabla A.19. Resultados para la predicción de Ra En-Línea utilizando los parámetros de corte y siete valores de MFCC de la fuerza en X. Cuatro números de neuronas en la capa oculta se probaron (6, 12, 24 y 25).

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
12x6x1	MSE ENT	0.020	0.021	0.020	0.023	0.022	0.018	0.019	0.022	0.019	0.024	0.021	0.002
	CF ENT	0.921	0.922	0.925	0.919	0.920	0.936	0.931	0.922	0.932	0.914	0.924	0.007
	MSE EVAL	0.031	0.028	0.033	0.049	0.036	0.034	0.029	0.029	0.031	0.040	0.034	0.006
	CF EVAL	0.904	0.899	0.888	0.821	0.874	0.875	0.891	0.893	0.888	0.845	0.878	0.026
12x12x1	MSE ENT	0.012	0.013	0.012	0.013	0.014	0.013	0.013	0.014	0.013	0.014	0.013	0.001
	CF ENT	0.953	0.953	0.956	0.953	0.951	0.955	0.955	0.950	0.955	0.952	0.953	0.002
	MSE EVAL	0.033	0.027	0.032	0.030	0.030	0.033	0.024	0.026	0.029	0.034	0.030	0.003
	CF EVAL	0.899	0.904	0.894	0.889	0.893	0.879	0.914	0.906	0.895	0.871	0.894	0.012
12x24x1	MSE ENT	0.008	0.009	0.010	0.009	0.008	0.008	0.007	0.008	0.008	0.008	0.008	0.001
	CF ENT	0.970	0.969	0.965	0.970	0.972	0.971	0.975	0.970	0.973	0.972	0.971	0.003
	MSE EVAL	0.036	0.028	0.031	0.035	0.027	0.034	0.031	0.033	0.027	0.043	0.032	0.005
	CF EVAL	0.891	0.902	0.895	0.877	0.906	0.879	0.890	0.883	0.905	0.847	0.888	0.017
12x25x1	MSE ENT	0.008	0.008	0.008	0.008	0.008	0.008	0.007	0.007	0.007	0.008	0.008	0.000
	CF ENT	0.970	0.971	0.973	0.974	0.971	0.972	0.976	0.974	0.974	0.973	0.973	0.002
	MSE EVAL	0.032	0.031	0.037	0.039	0.028	0.037	0.034	0.035	0.028	0.031	0.033	0.004
	CF EVAL	0.901	0.895	0.876	0.870	0.902	0.873	0.881	0.877	0.905	0.890	0.887	0.013

Tabla A.20. Resultados para la predicción de Ra En-Línea utilizando los parámetros de corte y siete valores de MFCC de la fuerza en Y. Cuatro números de neuronas en la capa oculta se probaron (6, 12, 24 y 25).

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
12x6x1	MSE ENT	0.021	0.027	0.021	0.026	0.021	0.019	0.021	0.022	0.019	0.021	0.022	0.003
	CF ENT	0.920	0.901	0.920	0.909	0.925	0.931	0.926	0.921	0.931	0.927	0.921	0.010
	MSE EVAL	0.040	0.041	0.034	0.042	0.034	0.031	0.030	0.039	0.035	0.034	0.036	0.004
	CF EVAL	0.872	0.853	0.884	0.836	0.878	0.884	0.887	0.855	0.873	0.867	0.869	0.016
12x12x1	MSE ENT	0.014	0.013	0.014	0.014	0.014	0.012	0.015	0.014	0.013	0.015	0.014	0.001
	CF ENT	0.947	0.954	0.949	0.953	0.953	0.959	0.949	0.949	0.952	0.948	0.951	0.004
	MSE EVAL	0.033	0.029	0.028	0.029	0.035	0.034	0.031	0.037	0.033	0.030	0.032	0.003
	CF EVAL	0.896	0.900	0.906	0.890	0.885	0.876	0.888	0.861	0.881	0.887	0.887	0.013
12x24x1	MSE ENT	0.009	0.009	0.011	0.009	0.010	0.010	0.011	0.008	0.009	0.009	0.009	0.001
	CF ENT	0.966	0.969	0.961	0.969	0.966	0.964	0.960	0.972	0.968	0.969	0.966	0.004
	MSE EVAL	0.032	0.033	0.029	0.037	0.029	0.036	0.029	0.035	0.037	0.029	0.032	0.003
	CF EVAL	0.902	0.889	0.903	0.865	0.900	0.876	0.900	0.876	0.868	0.890	0.887	0.015
12x25x1	MSE ENT	0.010	0.008	0.008	0.009	0.008	0.009	0.010	0.008	0.009	0.009	0.009	0.001
	CF ENT	0.962	0.972	0.970	0.968	0.972	0.969	0.966	0.972	0.968	0.968	0.969	0.003
	MSE EVAL	0.034	0.031	0.030	0.026	0.035	0.030	0.031	0.029	0.035	0.036	0.032	0.003
	CF EVAL	0.896	0.892	0.899	0.902	0.887	0.892	0.886	0.895	0.877	0.862	0.889	0.012

Tabla A.21. Resultados para la predicción Pre-Proceso de *Ra* utilizando la Nueva condición de desgaste en la herramienta. Se probaron tres estructuras diferentes, 5x5x1 con RPROP, 5x10x1 con RPROP y 5x10x1 con GDA.

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
5x10x1	MSE ENT	0.007	0.008	0.007	0.006	0.006	0.007	0.006	0.007	0.007	0.006	0.007	0.001
	MSE EVAL	0.011	0.008	0.010	0.014	0.013	0.012	0.013	0.012	0.011	0.014	0.012	0.002
	CF ENT	0.980	0.977	0.981	0.982	0.980	0.980	0.981	0.979	0.979	0.978	0.980	0.001
	CF EVAL	0.966	0.972	0.954	0.964	0.961	0.958	0.961	0.966	0.965	0.964	0.963	0.005
5x5x1	MSE ENT	0.007	0.009	0.007	0.006	0.006	0.008	0.008	0.008	0.007	0.007	0.007	0.001
	MSE EVAL	0.012	0.009	0.010	0.015	0.015	0.014	0.016	0.010	0.012	0.013	0.013	0.002
	CF ENT	0.978	0.975	0.980	0.982	0.980	0.976	0.976	0.976	0.978	0.977	0.977	0.002
	CF EVAL	0.964	0.971	0.952	0.962	0.957	0.951	0.952	0.968	0.962	0.965	0.960	0.007
5x10x1 GDA	MSE ENT	0.031	0.042	0.025	0.048	0.035	0.025	0.034	0.028	0.044	0.028	0.034	0.008
	MSE EVAL	0.032	0.043	0.027	0.046	0.042	0.046	0.059	0.023	0.078	0.046	0.044	0.016
	CF ENT	0.902	0.870	0.929	0.840	0.882	0.923	0.884	0.912	0.853	0.900	0.889	0.029
	CF EVAL	0.899	0.828	0.875	0.848	0.866	0.855	0.813	0.922	0.712	0.868	0.849	0.057

Tabla A.22. Resultados para la predicción Pre-Proceso de *Ra* utilizando la Semi-Nueva condición de desgaste en la herramienta. Se probaron tres estructuras diferentes, 5x5x1 con RPROP, 5x10x1 con RPROP y 5x10x1 con GDA.

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
5x10x1	MSE ENT	0.010	0.010	0.014	0.010	0.014	0.009	0.013	0.011	0.014	0.015	0.012	0.002
	MSE EVAL	0.022	0.027	0.016	0.021	0.011	0.022	0.017	0.021	0.013	0.009	0.018	0.006
	CF ENT	0.969	0.971	0.959	0.970	0.958	0.975	0.965	0.971	0.956	0.959	0.965	0.007
	CF EVAL	0.947	0.926	0.957	0.942	0.971	0.927	0.947	0.929	0.968	0.969	0.948	0.018
5x5x1	MSE ENT	0.013	0.012	0.016	0.014	0.016	0.011	0.016	0.012	0.015	0.019	0.014	0.003
	MSE EVAL	0.028	0.032	0.016	0.022	0.011	0.023	0.014	0.022	0.013	0.013	0.019	0.007
	CF ENT	0.958	0.966	0.954	0.960	0.952	0.969	0.955	0.969	0.955	0.946	0.958	0.008
	CF EVAL	0.930	0.915	0.957	0.941	0.969	0.927	0.956	0.924	0.969	0.957	0.944	0.020
5x10x1 GDA	MSE ENT	0.054	0.035	0.037	0.040	0.043	0.053	0.032	0.037	0.027	0.049	0.041	0.009
	MSE EVAL	0.053	0.041	0.044	0.064	0.045	0.070	0.028	0.039	0.025	0.037	0.044	0.014
	CF ENT	0.819	0.894	0.885	0.876	0.866	0.846	0.911	0.898	0.917	0.856	0.877	0.031
	CF EVAL	0.858	0.880	0.874	0.806	0.868	0.757	0.909	0.859	0.939	0.870	0.862	0.050

Tabla A.23. Resultados para la predicción Pre-Proceso de R_a utilizando la Semi-Desgastada condición de desgaste en la herramienta. Se probaron tres estructuras diferentes, 5x5x1 con RPROP, 5x10x1 con RPROP y 5x10x1 con GDA.

ANN	IND	1	2	3	4	5	6	7	8	9	10	PRO M	DSV ST
5x10x1	MSE ENT	0.014	0.022	0.023	0.020	0.023	0.021	0.013	0.022	0.016	0.023	0.020	0.004
	MSE EVAL	0.042	0.019	0.017	0.027	0.019	0.026	0.045	0.025	0.037	0.016	0.027	0.011
	CF ENT	0.947	0.919	0.921	0.930	0.912	0.917	0.948	0.907	0.945	0.917	0.926	0.015
	CF EVAL	0.866	0.928	0.924	0.901	0.946	0.918	0.871	0.947	0.850	0.938	0.909	0.035
5x5x1	MSE ENT	0.016	0.023	0.023	0.021	0.024	0.022	0.013	0.023	0.016	0.024	0.021	0.004
	MSE EVAL	0.041	0.019	0.018	0.029	0.018	0.027	0.045	0.027	0.037	0.016	0.028	0.010
	CF ENT	0.941	0.918	0.920	0.925	0.905	0.915	0.947	0.902	0.944	0.913	0.923	0.016
	CF EVAL	0.867	0.930	0.924	0.897	0.951	0.914	0.870	0.943	0.848	0.941	0.908	0.036
5x10x1 GDA	MSE ENT	0.024	0.032	0.042	0.029	0.052	0.037	0.040	0.038	0.039	0.042	0.037	0.008
	MSE EVAL	0.050	0.028	0.056	0.030	0.062	0.034	0.065	0.048	0.060	0.030	0.046	0.014
	CF ENT	0.911	0.882	0.849	0.896	0.784	0.852	0.835	0.836	0.860	0.844	0.855	0.036
	CF EVAL	0.829	0.893	0.777	0.885	0.803	0.889	0.778	0.879	0.751	0.884	0.837	0.056

Tabla A.24. Resultados para la predicción Pre-Proceso de R_a utilizando la Desgastada condición de desgaste en la herramienta. Se probaron tres estructuras diferentes, 5x5x1 con RPROP, 5x10x1 con RPROP y 5x10x1 con GDA.

ANN	IND	1	2	3	4	5	6	7	8	9	10	PROM	DSVST
5x10x1	MSE ENT	0.012	0.010	0.012	0.012	0.014	0.012	0.012	0.011	0.013	0.008	0.011	0.002
	MSE EVAL	0.012	0.018	0.014	0.015	0.010	0.014	0.014	0.016	0.014	0.031	0.016	0.006
	CF ENT	0.963	0.968	0.964	0.959	0.957	0.964	0.958	0.967	0.962	0.977	0.964	0.006
	CF EVAL	0.959	0.945	0.950	0.962	0.972	0.953	0.964	0.943	0.954	0.904	0.950	0.019
5x5x1	MSE ENT	0.014	0.012	0.013	0.013	0.014	0.012	0.012	0.011	0.013	0.008	0.012	0.002
	MSE EVAL	0.014	0.020	0.013	0.015	0.010	0.013	0.015	0.017	0.013	0.031	0.016	0.006
	CF ENT	0.958	0.962	0.963	0.956	0.956	0.963	0.957	0.967	0.961	0.976	0.962	0.006
	CF EVAL	0.954	0.940	0.954	0.962	0.971	0.959	0.962	0.939	0.954	0.902	0.950	0.019
5x10x1 GDA	MSE ENT	0.033	0.040	0.017	0.027	0.024	0.027	0.045	0.028	0.033	0.029	0.030	0.008
	MSE EVAL	0.064	0.043	0.019	0.034	0.024	0.031	0.059	0.038	0.060	0.044	0.042	0.015
	CF ENT	0.896	0.866	0.949	0.906	0.922	0.914	0.829	0.916	0.898	0.912	0.901	0.033
	CF EVAL	0.803	0.868	0.931	0.910	0.921	0.893	0.844	0.860	0.766	0.840	0.864	0.053

APÉNDICE B

DATOS PARA EXPERIMENTACIÓN

Tabla B.1. Experimentos con nuevos parámetros de validación para la estructura de ANN Pre-Proceso.

Exp.	f_z	D_{tool}	ae	HB	$Curv$	Ra	CTWC
1	0.075	12	3	109	0.0000	0.1614	N
2	0.075	12	3	109	0.0370	0.1756	N
3	0.075	12	3	109	0.01890	0.1436	N
4	0.075	12	3	111	-0.0303	0.1466	SN
5	0.075	12	3	111	0.0213	0.1432	SN
6	0.075	12	3	111	0.0000	0.1486	SN
7	0.075	12	3	110	0.0000	0.1582	SN
8	0.075	12	3	110	0.0833	0.1598	SN
9	0.075	12	3	110	-0.0556	0.145	SN
10	0.075	12	3	110	0.0250	0.1955	N
11	0.075	12	3	109	-0.0250	0.1504	N
12	0.0472	8	2	71	0.0000	0.2377	SN
13	0.0472	8	2	71	0.0769	0.2384	SN
14	0.0472	8	2	71	-0.0588	0.2023	SN
15	0.115	20	4.5	158	0.0000	0.2109	SN
16	0.115	20	4.5	158	0.0392	0.2685	SN
17	0.115	20	4.5	158	-0.0183	0.1467	SN
18	0.04	12	4	89	0.0000	0.1629	SD
19	0.04	12	4	89	0.0385	0.1965	SD
20	0.04	12	4	89	-0.0185	0.1361	SD
21	0.06	10	2	111	-0.0313	0.1265	SD
22	0.06	10	2	111	0.0208	0.1488	SD
23	0.06	10	2	111	0.0000	0.1370	SD
24	0.04	12	4	94	0.0000	0.2591	SD
25	0.04	12	4	94	0.0385	0.3218	SD
26	0.04	12	4	94	-0.0185	0.2866	SD
27	0.08	16	5	150	-0.0286	0.1559	D
28	0.08	16	5	150	0.0222	0.1653	D
29	0.08	16	5	150	0.0000	0.1624	D
30	0.08	16	5	151	-0.0286	0.1277	SD
31	0.08	16	5	151	0.0222	0.1262	SD
32	0.08	16	5	151	0.0000	0.1091	SD
33	0.025	8	1	110	-0.0323	0.2147	D

REFERENCIAS

- Benardos, P., Vosniakos, G. (2002). Prediction of Surface Roughness in CNC Face Milling using Neural Networks and Taguchi's Design Experiments. *Robotics and Computer Integrated Manufacturing* (18), 343–354.
- Benardos, P., Vosniakos, G. (2003). Predicting Surface Roughness in Machining: A Review. *International Journal of Machine Tools and Manufacture*, 833–844.
- Booker, L.B., Goldberg, D.E., Holland, J.H. (1989). Classifier Systems and Genetic Algorithms. *Artificial Intelligence*.
- Boothroyd, G., Knight, W.A. (2006). Fundamentals of Machining and Machine Tools. 3rd Ed. Taylor and Francis Group. 6000 Broken Sound Parkway NW, Suite 300 Boca Raton, FL USA
- David E. Goldberg (1989). Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley Longman Publishing Co., Inc., Boston, MA
- Liu, Z., Zhang, D. and Qi, H. (2006). Surface Roughness Modeling of High Speed Machining TC4 based on Artificial Neural Network Method. *Systems and Control in Aerospace and Astronautics*. 920-924.
- Nacsa, J. (2001). Intelligent Open CNC System based on the Knowledge Server Concept. *Digital Enterprise Challenges—IFIP Prolamat*, 7–10.
- Palanisamy, P., Rajendran, I., Shanmugasundaram, S. (2007). Optimization of Machining Parameters using Genetic Algorithm and Experimental Validation for End-Milling Operations. *International Journal of Advance Manufacturing Technologies* (32), 644-655.
- Suresh, P.V.S., Venkateswara, P., Deshmukh, S.G. (2002). A Genetic Algorithmic Approach for Optimization of Surface Roughness Prediction Model. *International Journal of Machine Tools & Manufacture* (42), 675-680.
- Tansel, I.N., Ozcelik, B., Bao, W.Y., Chen, P., Rincon, D., Yang, S.Y., Yenilmez, A. (2006). Selection of Optimal Cutting Conditions by using GONNS. *International Journal of Machine Tools & Manufacture* (46), 26-35.
- Tsai, Y.H., Chen, J.C. and Lou, S.J. (1999). An In-Process Surface Recognition System based on Neural Networks in End Milling Cutting Operations. *Machine Tools and Manufacture* (39), 583–605.

- Tönshoff, H. K., J. P. Wulfsberg, H. J. J. Kals, W. König and C. A. van Luttervelt (1988). Developments and Trends in Monitoring and Control of Machining Processes. *Annals of the CIRP* 37(2), 611-622.
- Vallejo, A., Morales-Menendez, R., Sucar, L.E. and Rodríguez, C.A. (2005). Tool-Wear Monitoring Based on Continuous Hidden Markov Models. *10th Iberoamerican Congress on Pattern Recognition*, 880–890.
- Vallejo, A., Morales-Menendez, R. and Elizalde, H. (2009). Surface Roughness Modeling in Peripheral Milling Processes. *North American Manufacturing Research Conference* (37).
- Wang, Z.H., Yuan, J.T., Hu, X.Q., Deng, W. (2009) Surface Roughness Prediction and Cutting Parameters Optimization in High-Speed Milling AlMn1Cu Regression and Genetic Algorithm. *International Conference on Measuring Technology and Mechatronics Automation*, 334-337.
- Zain, A., Haron, H., Sharif, S. (2008). An Overview of GA Technique for Surface Roughness Optimization in Milling Process. *International Symposium on Information Technology* (4), 1-6.
- Zain, A., Haron, H., Sharif, S. (2009). Genetic Algorithm for Optimizing Cutting Conditions of Uncoated Carbide (WC-Co) in Milling Machining Operation. *Conference on Innovative Technologies in Intelligent Systems and Industrial Applications*, 214-218.
- Zhang, G., Patuwo, B.E. and Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting* (14), 35-62.
- Zuperl, U., Čuš, F., Kiker, E. (2006). Intelligent Adaptive Cutting Force Control in End-Milling. *Technical Gazette* 13 (1,2), 15-22.

Tecnológico de Monterrey, Campus Monterrey



30002007422447

<http://biblioteca.mty.itesm.mx>